

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI**

**MESTRADO EM CIÊNCIA FLORESTAL**

**EDUARDA GABRIELA SANTOS CUNHA**

**QUANTIFICAÇÃO DE BIOMASSA EM FLORESTA ESTACIONAL  
SEMIDECIDUAL POR MEIO DE REDES NEURAIS ARTIFICIAIS**

**DIAMANTINA - MG**

**2015**

**EDUARDA GABRIELA SANTOS CUNHA**

**QUANTIFICAÇÃO DE BIOMASSA EM FLORESTA ESTACIONAL  
SEMIDECIDUAL POR MEIO DE REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal dos Vales do Jequitinhonha e Mucuri, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para a obtenção do título de Mestre.

**Orientador: Prof. Dr. Marcio Leles Romarco de Oliveira**

**DIAMANTINA - MG**

**2015**

Ficha Catalográfica - Sistema de Bibliotecas/UFVJM  
Bibliotecária: Jullyele Hubner Costa CRB-6/2972

C972q Cunha, Eduarda Gabriela Santos.  
2016 Quantificação de biomassa em floresta estacional semidecidual por meio de redes neurais artificiais / Eduarda Gabriela Santos Cunha. – Diamantina: UFVJM, 2016.  
75 p. : il.

Orientador: Prof. Dr. Marcio Leles Romarco de Oliveira  
Coorientador: Prof. Dr. Ricardo de Oliveira Gaspar  
Coorientador: Prof. Dr. Evandro Luiz Mendonça Machado

Dissertação (mestrado) –Universidade Federal dos Vales do Jequitinhonha e Mucuri. Programa de Pós-Graduação em Ciência Florestal, 2015.

1. Biomassa florestal. 2. Floresta natural. 3. Inteligência artificial.  
I. Oliveira, Marcio Leles Romarco de. II. Gaspar, Ricardo de Oliveira.  
III. Machado, Evandro Luiz Mendonça. IV. Título.

**CDD 581.981**

Elaborada com os dados fornecidos pelo(a) autor(a).

**EDUARDA GABRIELA SANTOS CUNHA**

**QUANTIFICAÇÃO DE BIOMASSA EM FLORESTA ESTACIONAL  
SEMIDECIDUAL POR MEIO DE REDES NEURAIAS ARTIFICIAIS**

Dissertação apresentada ao Programa de  
Pós-Graduação em Ciência Florestal, nível  
de Mestrado, como parte dos requisitos  
para obtenção do título de Mestre.

Orientador: Prof. Dr. Marcio Leles  
Romarco de Oliveira

Data da aprovação 27/11/2015

---

Prof. Dr. Alessandro Vivas Andrade – UFVJM

---

Prof. Dr. Eric Bastos Gorgens – UFVJM

---

Prof. Dr. Evandro Luiz Mendonça Machado – UFVJM

---

Prof. Dr. Marcio Leles Romarco de Oliveria – UFVJM

**DIAMANTINA**

**2015**

## **AGRADECIMENTOS**

A Deus pela vida, saúde, coragem, conforto, ânimo e força em todos os momentos.

A Universidade Federal dos Vales do Jequitinhonha e Mucuri – UFVJM e ao Programa de Pós Graduação em Ciência Florestal pela oportunidade e acolhimento.

A CAPES pelo apoio financeiro durante o mestrado.

Ao professor Marcio que se mostrou profissional e ético em todos os momentos, obrigada pela paciência e ensinamentos.

Aos membros da banca Alessandro Vivas Andrade, Eric Bastos Gorgens, Evandro Luiz Mendonça Machado e que contribuíram muito para o trabalho com discussão e dicas para melhoria.

Ao professor Dr. Ricardo Gaspar por ter gentilmente cedido os dados, possibilitando este estudo e ao Doutorando Eduardo Pelli que me ajudou no ponta pé inicial da pesquisa.

Aos amigos que eu trouxe da UFV e aqui em Diamantina tanto me ajudaram, Mariana Morena e Tarço, obrigada!

As amigas Gabi, Lidia, Eulália e Laila que aqui conquistei e vou levar para o resto da vida, que me ajudaram demais nesse trabalho (seja lendo, ouvindo dúvidas ou até mesmo dividindo horas de estudos) e também na estadia por essa cidade. Sem vocês teria sido difícil chegar ao final meninas, muito obrigada pelas conversas, confissões, dias e noites de dedicação e amizade!

Ao Átila Masutti que foi companheiro e amigo em todos os momentos, palavras são insuficientes pra expressar minha gratidão por tudo o que faz por mim e principalmente pelo o que fez nesse período. Nossa vida nunca mais será a mesma depois de Diamantina. Foi uma explosão de acontecimentos e emoções literalmente!!

E um agradecimento sem limites aos meus pais, que me proporcionam a busca pelo conhecimento, me encorajando, e dando apoio, carinho, amor, exemplo de honestidade e força pra lutar pelos meus objetivos.

Aos colegas do laboratório de Manejo e Mensuração Florestal e aos demais colegas de disciplinas que dividiram comigo momentos de tensão e boas risadas! A todos que me ajudaram indiretamente, a minha família na torcida e orações, meus amigos de Porto e de Viçosa com a energia positiva e carinho de sempre e que aos que não mencionei mas fizeram parte dessa etapa importante da minha vida pessoal e profissional, o meu MUITO OBRIGADA!

Dedico este trabalho aos meus pais, Maria das Graças Santos e Porfírio Augusto da Cunha Neto pelo esforço para que eu chegasse até aqui, pela compreensão da minha ausência em tantos momentos importantes durante esses anos, pela confiança que depositam em mim em todas as minhas escolhas. Vocês são e sempre serão meu Porto Seguro!

## RESUMO

CUNHA, E. G. S. **Quantificação de biomassa em floresta estacional semidecidual por meio de redes neurais artificiais**. 2015. 77 p. (Dissertação – Ciência Florestal) – Universidade Florestal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2015.

A predição de biomassa em florestas naturais é complexa devido à variação de espécies, de estágio sucessional, características edáficas e climáticas das áreas, dentre outras, e isso gera uma grande demanda de informações para que se tenha estimativas de biomassa confiáveis. O objetivo deste estudo foi de quantificar a biomassa arbórea aérea de um fragmento de floresta Estacional Semidecidual em Minas Gerais - MG por meio de redes neurais artificiais (RNA). Assim como, avaliar a influência das variáveis categóricas fitofisionomia (*FT*), infestação de cipó (*CP*), qualidade de copa (*QC*) e coeficiente de De Liocourt (*q*) na estimativa de biomassa. Foi empregada a técnica de validação cruzada (*cross-validation*) para definição da topologia e validação das redes, em que a estimativa de erro global é calculada como a média das *k* estimativas de erro de cada iteração (admitiu-se *k*=10). Variou-se o número de neurônios na camada escondida e avaliou-se a média e o desvio padrão do erro médio quadrático (*EMQ*) dos resultados da validação cruzada para definir o número de neurônios na camada escondida, que melhor se adequou ao problema. Para definir a RNA mais adequada para cada situação, uma nova validação cruzada foi realizada e avaliação se deu pelos ajustes das RNA (*EMQ*,  $r_{Y\hat{Y}}$ , Bias e Variância) e análise gráfica dos resíduos. A biomassa observada média foi de 110,81 t.ha<sup>-1</sup> e a biomassa média estocada por hectare foi estimada em 114,41 t.ha<sup>-1</sup> pela RNA 3 e 116,34 t.ha<sup>-1</sup> pela RNA 7. As RNA 3 (variáveis de entrada: *DAP*, *d*, *Hf*, *Vt*, *CP*) e 7 (variáveis de entrada: *DAP*, *d*, *Ht*, *Vt*, *CP*, *QC*) se ajustaram melhor, obtendo menores resíduos. No entanto, a RNA 7 que contém *CP* e *QC* associadas como variável de entrada da rede, teve bom desempenho devido à contribuição da variável *CP*, visto que a RNA 4 que contém apenas *QC* não foi precisa na maioria das parcelas, esse fato pode estar relacionado a maior subjetividade na avaliação da qualidade de copa. A RNA 3 foi mais adequada visando simplicidade na coleta de campo, acarretando menor tempo e custo.

Palavras-chave: Biomassa Florestal , Floresta natural, Inteligência artificial.



## ABSTRACT

CUNHA, E. G. S. **Biomass quantification in semideciduous forest through artificial neural networks**. 2015. 77 p. (Dissertação – Ciência Florestal) – Universidade Florestal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2015.

The prediction of biomass in natural forests is complex due to the variation of species in successional stages, characteristics of soil and climate of areas, among other things, and this generates a large demand for information in order to produce reliable biomass estimates. This study aimed to quantify the aerial tree biomass from a fragment of semideciduous forest in Minas Gerais - MG through artificial neural networks (ANN). Moreover, this study evaluated the influence of categorical variables including phytophysiology, vine infestation, canopy quality and the De Liocourt quotient in estimation of biomass. All the analysis was done using R software, using the cross-validation technique to define the topology and validation of networks, wherein the global error estimate is calculated as the average of  $k$  error estimates of each iteration (assuming  $k = 10$ ). The number of neurons in the hidden layer varied, and the mean and standard deviation of the mean square error (MSE) were evaluated by the results of cross-validation in order to determine the number of neurons in the hidden layer, which best adapted to the problem. To determine the most appropriate ANN in each situation, a new cross-validation was conducted and the evaluation was completed using the results of the ANN (MSE, Correlation coefficient, Bias and Variance) and graphical residue analysis. The average observed biomass was  $110.81 \text{ t.ha}^{-1}$  and the average stored biomass per hectare was estimated to be  $114.41 \text{ t.ha}^{-1}$  using ANN 3 and  $116.34 \text{ t.ha}^{-1}$  using 7 ANN. This study found that the ANN 3 (input:  $DAP$ ,  $d$ ,  $Hf$ ,  $Vt$ ,  $CP$ ) and 7(input:  $DAP$ ,  $d$ ,  $Ht$ ,  $Vt$ ,  $CP$ ,  $QC$ ) had greater precision than the other ANNs, obtaining smaller residue. However, due to the association of vine infestation and crown quality in ANN 7 as input variable network, the good performance possibly because of the variable contribution of the vine infestation, whereas ANN 4 which contains only canopy quality was not more accurate in the majority of plots, this may be related to greater subjectivity in assessing the canopy quality, and in this way. ANN 3 was more appropriate in terms of simplifying field sampling, leading to reduced time and cost.

Keywords: Forest biomass , natural forest , artificial intelligence.

## LISTA DE FIGURAS

Figura 1 - Estrutura da arquitetura da rede Perceptron de Múltiplas Camadas – MPL.....	19
Figura 2- Situações envolvendo <i>underfitting</i> e <i>overfitting</i> .....	22
Figura 3 - Método de validação cruzada usando k partições.....	23
Figura 4 - Diagrama de blocos das fases de treinamento e operação.....	24
Figura 5 - Relação entre variáveis Diâmetro à 1,30 do nível do solo ( <i>DAP</i> ), Altura total ( <i>Ht</i> ), Altura de fuste ( <i>Hf</i> ), Biomassa e Volume.....	55
Figura 6 – Distribuição do número de indivíduos por hectare por classe de diâmetro em cm, e o coeficiente de De Liocourt. Em que CCD é o centro da classe diamétrica e ‘q’ é coeficiente de De Liocourt para a referente CCD.....	56
Figura 7 - Definição da topologia para estimativas de biomassa total. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.....	58
Figura 8 - Relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e histograma de frequência de resíduos. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.....	62

## LISTA DE TABELAS

Tabela 1 - Caracterização das áreas de estudo.....	47
Tabela 2 - Variáveis de entrada das redes neurais artificiais.....	50
Tabela 3 - Descrição das variáveis contínuas utilizadas como entradas das RNA. Em que DAP - Diâmetro à 1,30 m do solo, Ht - Altura Total, Hf - Altura de fuste, Vt - Volume total e as respectivas saída Bt - Biomassa total.....	54
Tabela 4 - Características das RNA para estimar biomassa total de uma Floresta Estacional Semidecidual em Minas Gerais. Em que DAP = diâmetro a 1,30 m do nível do solo ; $d$ = densidade básica da madeira; $Ht$ = altura total; $Hf$ = altura de fuste; $Vt$ = volume total; $FT$ = Fitofisionomia; $CP$ = infestação de cipós; $QC$ = qualidade de copa; $q$ = coeficiente de De Liocourt; $Bt$ = biomassa total; $EMQ_{\text{médio}}$ = erro médio quadrático médio; Sd = desvio padrão; número de variáveis da camada de entrada (camada E), número de neurônios da camada intermediária (camada I) e número de variáveis da camada de saída (camada S).....	60
Tabela 5 - Arquiteturas das RNA selecionadas para estimativa de biomassa total de uma Floresta Estacional Semidecidual em Minas Gerais e suas respectivas estatísticas. Em que $DAP$ = diâmetro a 1,30 m do nível do solo ; $d$ = densidade básica da madeira; $Ht$ = altura total; $Hf$ = altura de fuste; $Vt$ = volume total; $FT$ = fitofisionomia; $CP$ = infestação de cipós; $QC$ = qualidade de copa; $q$ = coeficiente de De Liocourt; $Bt$ = biomassa total; $EMQ$ = erro médio quadrático e $r_{Y\hat{Y}}$ = coeficiente de correlação.....	61
Tabela 6 - Biomassa observada e estimada por meio de RNA para uma Floresta Estacional Semidecidual em Minas Gerais, em que Parc = Parcela; Ind = Indivíduo; Res = Resíduo; RNA 1 = Variáveis contínuas na entrada ( $DAP$ , $d$ , $Ht$ , $Vt$ ); RNA 2, 3, 4, 5, 6, 7 = Variáveis contínuas/categóricas (RNA 2- $DAP$ , $d$ , $Ht$ , $Vt$ , $FT$ ; RNA 3 - $DAP$ , $d$ , $Hf$ , $Vt$ , $CP$ ; RNA 4 - $DAP$ , $d$ , $Ht$ , $Vt$ , $QC$ ; RNA 5 - $DAP$ , $d$ , $Ht$ , $Vt$ , $q$ ; RNA 6 - $DAP$ , $d$ , $Ht$ , $Vt$ , $FT$ , $CP$ , $QC$ , $q$ ; RNA 7 - $DAP$ , $d$ , $Ht$ , $Vt$ , $CP$ , $QC$ ).....	69

## SUMÁRIO

<b>LISTA DE FIGURAS .....</b>	<b>9</b>
<b>LISTA DE TABELAS.....</b>	<b>10</b>
<b>INTRODUÇÃO GERAL.....</b>	<b>12</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>13</b>
<b>CAPÍTULO 1 - REFERENCIAL TEÓRICO.....</b>	<b>15</b>
<b>1. REDES NEURAIS ARTIFICIAS (RNA).....</b>	<b>15</b>
1.1. Fase de treinamento de uma RNA.....	18
<b>2. APLICAÇÕES DE RNA NA ÁREA FLORESTAL .....</b>	<b>24</b>
2.1. Estimativa de biomassa por meio de RNA.....	27
<b>3. MÉTODOS DE QUANTIFICAÇÃO DE BIOMASSA EM FLORESTAS .....</b>	<b>28</b>
3.1. Métodos diretos.....	29
3.2. Métodos indiretos.....	31
3.3. Divergências de opiniões sobre os métodos de quantificação de biomassa.....	32
<b>4. BIOMASSA EM DIFERENTES COMPARTIMENTOS DA FLORESTA .....</b>	<b>34</b>
<b>5. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>36</b>
<b>CAPÍTULO 2 - ESTIMATIVA DE BIOMASSA EM FLORESTA ESTACIONAL SEMIDECIDUAL POR MEIO DE REDES NEURAIS ARTIFICIAIS .....</b>	<b>43</b>
<b>1. INTRODUÇÃO .....</b>	<b>43</b>
<b>2. OBJETIVOS.....</b>	<b>44</b>
<b>3. MATERIAL E MÉTODOS.....</b>	<b>45</b>
3.1. Caracterização da área de estudo .....	45
3.2. Coleta e processamento de dados.....	46
3.2.1 Distribuição diamétrica .....	47
3.2.2. Obtenção do volume.....	47
3.2.3 Obtenção da biomassa.....	48
3.3. Obtenção da biomassa por meio de RNA .....	48
3.3.1. Avaliação da qualidade das RNA.....	51
<b>4. RESULTADOS E DISCUSSÃO .....</b>	<b>51</b>
4.1. Análise Exploratória dos Dados.....	51
4.2. Definição da topologia .....	55
4.3. Estimativa de biomassa por meio de RNA.....	58
<b>5. CONCLUSÃO .....</b>	<b>70</b>
<b>6. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>70</b>
<b>APÊNDICE A .....</b>	<b>74</b>

## INTRODUÇÃO GERAL

Um dos desafios deste século provavelmente é a problemática da mudança climática, que é agravada ao longo dos anos pelo acúmulo de gases de efeito estufa na atmosfera, principalmente pela queima de combustíveis fósseis provocada por padrões não sustentáveis de consumo.

Neste contexto, ações globais de redução de emissões de gases de efeito estufa tornam-se necessárias (IPAM, 2014). Os países em desenvolvimento também serão cobrados pela mudança do clima, sendo exigidos deles, esforços contínuos na busca do desenvolvimento sustentável.

O Brasil possui 463 milhões de hectares (54,4% do seu território) de florestas naturais e plantadas. Sendo 98,45% do total da área florestada ocupado por diferentes biomas compondo a floresta natural brasileira (SFB, 2013). A Mata Atlântica é considerada um complexo de ecossistemas de grande importância e detém grande parte da diversidade biológica. Os altos níveis de riqueza e endemismo, associados à destruição sofrida no passado, a incluiu definitivamente no cenário mundial como área prioritária para conservação. A Floresta Estacional Semidecidual é uma das fitofisionomias florestais que compõem o bioma Mata Atlântica, possuindo como característica principal o fato de suas espécies serem em grande parte caducifólias (MITTERMEIER et al., 2004; RAMOS et al., 2008).

A floresta é considerada uma fonte de energia limpa, pois a emissão de carbono por usos esporádicos e planejados não contribui para o aumento dos gases nocivos à atmosfera, e quando bem manejada, ela continua a desempenhar seu papel natural de “sumidouro” de forma efetiva (SILVEIRA et al., 2008). Além de armazenar o carbono em seus tecidos, há a devolução de parte deste carbono retido por meio do derramamento periódico de folhas, galhos, frutos e, por vezes, árvores inteiras (GOLLEY, 1983).

As florestas brasileiras detêm cerca de 80 bilhões de toneladas de carbono, equivalente à queima de combustíveis fósseis de todo o mundo durante uma década (PARKER et al., 2009). E é a quantidade de biomassa em uma floresta que determina o potencial de estocagem de carbono. Dessa forma, é imprescindível que a biomassa seja determinada e estimada de forma confiável.

Os estudos para quantificação de biomassa florestal em geral utilizam-se de métodos diretos, para obtenção das variáveis. Nos métodos diretos há a necessidade de se retirar amostras em campo para a determinação da variável biomassa, o que pode ser uma restrição

para o uso do método. Em contrapartida, o método indireto possibilita a estimativa de biomassa, por meio de relações quantitativas ou matemáticas, baseadas em dados originados de inventários florestais ou por dados de sensoriamento remoto (SILVEIRA et al., 2008; MOGNON et al., 2013).

As metodologias indiretas mais utilizadas para o cálculo de biomassa são aquelas que realizam o ajuste de equações pelo uso de técnicas de regressão. Porém, técnicas mais recentes, conhecidas como Redes Neurais Artificiais (RNA), baseadas na capacidade de mapeamentos não lineares e aprendizagem por meio de exemplos, têm sido aplicadas com sucesso nas mais diversas áreas (ALMEIDA et al., 2009), devendo ser estudadas também para a finalidade de quantificação de biomassa.

No ramo da Ciência Florestal, diversas questões podem ser resolvidas por meio de RNA, dentre elas a modelagem do volume de árvores, prognose da produção madeireira e não madeireira, predição de altura, dentre outros. A predição de biomassa, em especial em florestas naturais, por meio de RNA ainda é pouco frequente, justificando a necessidade de maiores estudos.

É comum o emprego de softwares de código fechado para processamento de RNA, em que não se pode modificar ou ler as linhas que foram escritas pelo programador. Alternativamente, o software R, que é de código aberto e proporciona o conhecimento e definição das características da RNA, disponibiliza uma ampla variedade de técnicas estatísticas como ferramenta de análise e apresentação gráfica de dados.

Dessa forma, objetivou-se quantificar a biomassa de um fragmento de Floresta Estacional Semidecidual por meio da ferramenta de inteligência artificial, as RNA, como uma alternativa aos métodos tradicionais.

O estudo foi estruturado em dois capítulos, sendo o primeiro uma revisão de literatura, e o segundo uma aplicação da metodologia de RNA para quantificação de biomassa.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. C.; BARROS, P. L. C; MONTEIRO, J. H. A; ROCHA, B. R. P. Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing. In: **IEEE Latin America Transactions**. Piscataway, v. 7, n. 1, p. 27-32, 2009.

GOLLEY, F. B. **Tropical rain forest ecosystems: structure and function**. Elsevier, Amsterdam, 1983. 392 p.

INSTITUTO DE PESQUISA AMBIENTAL DA AMAZÔNIA (IPAM). **Estimulando a demanda para reduções de emissões do REDD+ no Brasil. A necessidade de uma**

**intervenção estratégica pré -2020:** um estudo de caso para o projeto Finanças Florestais Interinas. Brasília, Brasil. Publicado pelo Global Canopy Program, Oxford, UK. 2014.

MITTERMEIER, R. A.; GIL, P.R.; HOFFMAN,M.; PILGRIM, J.; BROOKS, T.; MITTERMEIER, C. G.; LAMOUREX, J. & FONSECA, G. A. B. 2004. **Hotspots revised**. CEMEX, Mexico City, 392p.

MOGNON, F.; DALLAGNOL, F. S.; SANQUETTA, C. R.; CORTE, A. P. D.; BARRETO, T. G. Uma década de dinâmica de fixação de carbono na biomassa arbórea em Floresta Ombrófila Mista no Sul do Paraná. **Floresta**. Curitiba - PR, v. 43, n. 1, p. 153-164, 2013.

PARKER, C.; MITCHELL, A.; TRIVEDI, M.; MARDAS, N. **The little REDD+ Book**. Global Canopy Foundation, 2009. 138p.

RAMOS, V. S.; DURIGAN, G.; FRANCO, G. A. D. C.; SIQUEIRA, M. F. de; RODRIGUES, R. R. **Árvores da floresta estacional semidecidual: guia de identificação de espécies**. São Paulo: Edusp, 2008. 312 p.

SERVIÇO FLORESTAL BRASILEIRO (SFB). **Florestas do Brasil em resumo:** dados de 2007 - 2012. Brasília: SFB, 2013. 188 p.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**. Curitiba - PR, v. 38, n. 1, p. 185 - 206, 2008.

## CAPÍTULO 1 - REFERENCIAL TEÓRICO

### 1. REDES NEURAIS ARTIFICIAS (RNA)

A Inteligência Artificial (IA) é uma forma de simular os processos de inteligência humana por máquinas, automatizando as atividades que associamos ao comportamento e pensamento humano, como a tomada de decisões, a resolução de problemas e o aprendizado. Várias técnicas importantes de IA têm suas origens na Biologia, uma vez que diversos algoritmos foram inspirados na evolução biológica (RUSSEL, 2004; ARTERO, 2009). As redes neurais artificiais (RNA) estão incluídas no campo da IA sob o paradigma de aprendizado por meio de experiência.

Estudos envolvendo RNA iniciaram-se com a publicação de McCulloch e Pitts (1943) que criaram o primeiro modelo artificial de um neurônio biológico e propuseram uma arquitetura para a RNA. Em seguida Hebb (1949) apresentou o primeiro método de treinamento para RNA, baseado no aprendizado em neurônios biológicos. Logo após, outros pesquisadores foram aprimorando o conhecimento de redes neurais e suas funcionalidades, porém, Minsky e Papert (1969) relataram limitações nas RNA conhecidas até aquele momento (Perceptron de única camada), quando os problemas não eram linearmente separáveis. Eles não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, então concluíram que as redes neurais seriam sempre suscetíveis a essa limitação. Durante os anos 70 poucas pesquisas foram publicadas e a área ficou “adormecida” (BRAGA et al., 2007). No entanto, Rumelhart, Hinton e Williams (1986), ao desenvolverem o algoritmo de treinamento de retropropagação do erro (*backpropagation*), mostraram que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de RNA mais utilizado atualmente, as redes Perceptron de múltiplas camadas. A partir disso, retomaram-se as pesquisas e surgiram diversos trabalhos com aplicações de RNA nas mais diferentes áreas do conhecimento.

A estrutura das RNA foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano (que é regido por elementos processadores biológicos que operam em paralelo, tendo como objetivo a produção de ações apropriadas para cada uma de suas funcionalidades). Os elementos computacionais ou unidades processadoras, conhecidas como neurônios artificiais, são modelos bem simplificados dos neurônios biológicos (SILVA et al., 2010).



Dentre as características de similaridade das RNA com o cérebro humano, está a capacidade de aprender algo por meio de exemplos. As RNA's são sistemas paralelos distribuídos compostos por unidades de processamento simples, os neurônios artificiais, que calculam determinadas funções matemáticas, armazenando conhecimento experimental e tornam esse conhecimento disponível para uso. Essa função matemática é a função de ativação que serve para restringir a amplitude da saída do neurônio. A função de ativação limita as entradas a uma amplitude finita, normalmente no intervalo fechado entre 0 e 1 ou alternativamente entre -1 e 1 (HAYKIN, 2001).

Os neurônios artificiais são dispostos em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. As camadas de uma rede podem ser classificadas em: entrada, onde ocorre o recebimento dos dados, e as variáveis são inseridas na rede; oculta ou intermediária onde há a extração de características, e a maior parte do processamento de sinal ocorre; e saída, onde finaliza o processo e há a produção e apresentação do resultado final da rede. Na maioria dos modelos as conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pelo modelo (HAYKIN, 2001; BRAGA et al., 2007). A forma como essas conexões estão organizadas (e como os neurônios estão dispostos uns em relação aos outros) definem a arquitetura de uma RNA. Considerando determinada arquitetura, as diferentes formas de composições estruturais que uma RNA pode assumir definem a topologia de uma RNA, levando em consideração o número de neurônios nas camadas ocultas (SILVA et al., 2010).

A primeira decisão que se deve tomar ao utilizar uma RNA para resolução de um problema deve ser quanto à arquitetura da rede de acordo com Gorgens et al. (2014), pois a partir dela se definem as características de aprendizagem.

As principais arquiteturas podem ser divididas em: redes alimentadas adiante (*feedforward*) de uma única camada, que são consideradas mais simples no qual todas as sinapses estão interligadas somente aos neurônios da camada seguinte, propagando os sinais de entrada para a próxima camada apenas; redes *feedforward* de múltiplas camadas que além de ter a camada de entrada e de saída, também possui uma ou mais camadas intermediárias, onde os neurônios de cada uma das camadas possuem como entrada a saída do neurônio da  $n$  próxima camada, sendo alimentada sempre para frente; redes reticuladas, utilizadas na extração de características; e as redes recorrentes, nas quais, há sinapses com os neurônios da mesma camada ou com os da camada anterior, tendo pelo menos um ciclo, realimentando a saída de neurônios para os demais neurônios da rede (HAYKIN, 2001; SILVA et al., 2010).

As redes com uma única camada têm a limitação de resolver apenas problemas com características lineares. No entanto, é sabido que as não-linearidades são inerentes à maioria das situações e problemas reais, sendo necessária, portanto, a utilização de estruturas com características não-lineares para a resolução de problemas de maior complexidade (BRAGA et al., 2007). Para as redes com mais de uma camada, a resposta da camada mais externa da mesma corresponde à composição das respostas dos neurônios das camadas anteriores. À RNA de múltiplas camadas composta por neurônios de ativação sigmoidais nas camadas intermediárias dá-se o nome de Perceptron de Múltiplas Camadas (MLP do inglês Multilayer Perceptron) e são caracterizadas pelas elevadas possibilidades de aplicações, consideradas uma das arquiteturas mais versáteis (SILVA et al., 2010).

Uma rede MLP típica possui como características principais o fato dos neurônios das camadas intermediárias (e, às vezes, os da camada de saída) possuírem uma função de ativação não-linear do tipo sigmoidal (função logística ou tangente hiperbólica); a rede ser constituída de uma ou mais camadas intermediárias, possuindo um alto grau de conectividade; e os dados serem recebidos pela camada de entrada (onde cada neurônio representa uma variável de entrada do problema) e processados nas camadas intermediária e de saída (HAYKIN, 2001; BRAGA et al. 2007).

Valença (2010) complementa que a camada intermediária (camada oculta) é responsável pela não linearidade da rede. A definição do número de neurônios nessa camada é importante pois, quanto maior esse número, maior é a capacidade de mapeamento não linear, porém um número muito grande pode levar a perda de capacidade de generalização da rede, neste caso a rede será superajustada. Da mesma forma, um número muito pequeno, leva a perda da capacidade de aproximação, tornando a rede subajustada.

A estrutura básica de uma rede Perceptron de Múltiplas Camadas, com uma camada oculta, é apresentada na Figura 1.




Figura 1 - Estrutura da arquitetura da rede Perceptron de Múltiplas Camadas – MPL.

### 1.1. Fase de treinamento de uma RNA

Em RNA, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, em que um conjunto de exemplos é apresentado para a rede, que extrai as características necessárias para representar a informação fornecida e as utiliza posteriormente para gerar respostas para o problema (BRAGA et al., 2007).

O aprendizado ou treinamento consiste no ajuste dos pesos da rede (que armazenam no final do processo o conhecimento que a rede adquiriu do ambiente externo) e a eficiência do mesmo está diretamente relacionada aos parâmetros do algoritmo utilizado para o treinamento, com a topologia e com o número de camadas. De acordo com Haykin (2001) o treinamento pode ser dividido em dois grupos: supervisionado e não supervisionado. O treinamento mais usual na área florestal é o supervisionado em que são oferecidos à rede padrões de entrada e saída. Dados de entrada são processados pela rede, e a saída atual é comparada com a saída desejada, oriunda do conhecimento prévio do ambiente. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, e esse ajuste ocorre até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo.

No treinamento não supervisionado, não há conhecimento prévio do ambiente externo. São oferecidas à rede as condições necessárias para uma análise, que é feita tomando-se por base as regularidades apresentadas pelos dados. O processo de treinamento pode ser dividido em três partes distintas. A priori, a rede neural é estimulada pelo ambiente. Em resposta a esse estímulo, no segundo estágio, ocorre a alteração dos seus parâmetros livres. Por fim, a rede neural passa a responder de uma nova maneira ao ambiente que a estimula (HAYKIN, 2001).

Todo o conhecimento adquirido pela rede fica acumulado nos pesos sinápticos. Analogamente à sinapse do neurônio biológico, o peso é a “memória” da rede.

De acordo com Haykin (2001) e Valença (2010), o algoritmo mais utilizado para efetuar o aprendizado supervisionado em RNA do tipo MLP é o de retropropagação do erro (*backpropagation*). No processo de retropropagação do erro apresenta-se à rede um exemplo e verifica-se a saída da rede. Esta saída é comparada à saída esperada, dando um erro. Calcula-se o gradiente deste erro com relação aos valores sinápticos da camada de saída, que é atualizada, podendo-se então calcular o erro da saída da penúltima camada, e assim por diante, atualizando todas as camadas das conexões. Os pesos das conexões das unidades das camadas internas vão sendo modificados utilizando a regra delta generalizada. A seguir apresenta-se mais um exemplo e continua-se o processo até que o erro seja menor que uma tolerância desejada (HAYKIN, 2001; BRAGA et al., 2007; SILVA et al., 2010).

Dois importantes parâmetros do algoritmo de aprendizagem são: a taxa de aprendizagem e o termo *momentum*. A taxa de aprendizagem indica o quão rápido a rede processa a informação, consequentemente, o treinamento é acelerado quando há altos valores dessa taxa, porém isso pode causar instabilidade e saturação; as alterações de peso podem ultrapassar o erro mínimo e os pesos irão oscilar, ou até mesmo divergir. Da mesma forma, valores muito pequenos não são desejáveis pois aumenta a probabilidade do modelo ficar preso a mínimos locais e podem tornar o treinamento bastante lento (demora muito para chegar perto do erro mínimo). Os valores dessa taxa de aprendizagem estão situados entre  $0 < \alpha < 1$  (VALENÇA, 2005). A definição do valor ideal é um problema que depende da rede utilizada e do problema tratado, e essa taxa pode variar durante o processo de treinamento, portanto há necessidade de manter a taxa de aprendizado sem que a mesma leve à oscilação e impeça a convergência do processo de aprendizado. Uma maneira de aumentar a velocidade de treinamento da rede e reduzir o perigo de instabilidade incluir o termo *momentum*, uma constante que determina o efeito das mudanças passadas dos pesos na direção atual do movimento no espaço de pesos, buscando a menor chance do modelo ficar preso a mínimos locais (HAYKIN, 2001; BRAGA et al., 2007).

Para que haja maior sucesso do algoritmo de treinamento, em especial, o de retropropagação do erro, é importante que haja ações de pré-processamento dos dados. Essas ações reduzem a redundância de dados e as chances dos mesmos se tornarem inconsistentes. A normalização, por exemplo, é efetuada para equiparar as variáveis com intervalos diferentes (as variáveis normalizadas recebem igual atenção durante o treinamento), transformando os

valores reais em valores equivalentes dentro do intervalo de amplitude das funções de ativação (VALENÇA, 2010).

Quando uma RNA é treinada em excesso (*overfitting*) aprende fortemente os dados de treinamento e pode apresentar uma péssima capacidade de generalizar o conhecimento adquirido, tendendo a memorizar os exemplos de treinamento. Dessa forma, pode-se utilizar uma técnica que pode guiar a parada da rede a fim de evitar o *overfitting*, que é a validação cruzada (VALENÇA, 2010).

### 1.1.1 Validação Cruzada

A validação cruzada é uma técnica da estatística utilizada para avaliar a capacidade de generalização de um modelo (STONE, 1978). No contexto das RNA, o objetivo desta técnica é avaliar a generalização do conhecimento adquirido durante a fase de treinamento (AMARI et al., 1996), indicando se o modelo conseguiu extrair as principais informações da rede, sendo muito utilizada em problemas que envolvem predição. Dessa forma, busca-se estimar a acurácia do modelo em relação ao seu desempenho para um novo conjunto de dados.

O método divide o banco de dados em dois subconjuntos: treinamento e teste, no primeiro constam os dados a serem utilizados para gerar um modelo adequado que “aprende” as “características” fornecidas, e o conjunto de teste conta com exemplos independentes que não foram usados na geração do modelo e é usado para testar ou validar a rede treinada, que apresentou os melhores resultados da generalização.

Para definir a topologia adequada ao problema é preciso utilizar uma metodologia de validação de modelos e a validação cruzada pode ser utilizada para esse fim (KOHAVI, 1995; HAYKIN, 2001; SILVA et al., 2010). A escolha equivocada e o aumento indiscriminado do número de neurônios pode levar a RNA à memorização excessiva (*overfitting*), situação em que as respostas, frente aos estímulos introduzidos em suas entradas, serão um conjunto de saídas decoradas. Por outro lado, um número reduzido de neurônios também não é adequado, podendo ser insuficiente para extração de informações e armazenamento de informações necessárias para ser capaz de realizar o mapeamento desejado (*underfitting*) (SILVA et al., 2010).

A validação cruzada permite que haja a avaliação de ocorrência de *overfitting* e *underfitting*, por meio de um procedimento de parada antecipada (*early stopping*), em que o processo de aprendizagem para uma topologia candidata é constantemente checado pela aplicação dos subconjuntos de teste, sendo finalizado quando começa a haver elevação do

erro quadrático (frente ao subconjunto de teste) entre épocas sucessivas. Como critérios de parada pode-se ter, por exemplo, o número máximo de épocas (apresentação de todos os padrões de treinamento disponível); a fixação de um erro mínimo.

Na Figura 2 é apresentada uma situação em que ocorre uma parada no treinamento quando a topologia (número de neurônios da camada oculta nesse exemplo foi de 10 neurônios) mais adequada foi definida por meio da metodologia de validação cruzada, e poderia representar o número de épocas ideal para parar o treinamento (no exemplo, 10 épocas seriam suficiente).




Figura 2: Situações envolvendo *underfitting* e *overfitting*.

Fonte: SILVA et al., 2010.

Três métodos de validação cruzada são geralmente empregados no processo de seleção de redes MLP, sendo eles: Método de validação cruzada por amostragem aleatória (*random subsampling cross-validation*), em que a amostra (conjunto total de dados) é aleatoriamente dividida em subconjunto de treinamento e subconjunto de teste (validação); Método de validação cruzada por unidade (*leave-one-out cross-validation*), em que ao particionar o conjunto de dados em subconjuntos, um subconjunto é selecionado para teste, sendo os demais utilizados para o treinamento; e o método de validação cruzada adotado para o dimensionamento estrutural das redes MLP (*k-fold cross-validation*) (SILVA et al., 2010).

O método *k-fold cross-validation* consiste na divisão dos dados conhecidos (conjunto total de amostras), em  $k$  partições. Dessas partições,  $k-1$  são utilizadas para compor o subconjunto de treinamento, e a partição restante fará parte do subconjunto de teste. Dessa forma, o processo de aprendizado é repetido  $k$  vezes até que todas as partições tenham sido utilizadas alternadamente para formar o subconjunto de teste ou validação, evitando dessa forma a superposição dos mesmos. A cada iteração realizada são feitos “ $k$ ” treinamentos e

aplicações, de cada RNA treinada, ao grupo de validação. Por fim, calcula-se o erro médio quadrático referente a cada aplicação de topologias testadas. A determinação da topologia se dá pelo menor erro médio quadrático médio ( $EMQ_{médio}$  - média entre os desempenhos individuais observados quando da aplicação de  $k$  partições) associado ao desvio padrão dos erros. O cálculo do  $EMQ$  correspondente à validação cruzada é realizado sempre que se conclui um ciclo, isto é, a cada ciclo após o reajuste dos pesos o treinamento é parado e o conjunto de validação cruzada é apresentado à rede para que se possa calcular o erro.

Um exemplo do método de validação cruzada *k-fold cross-validation* pode ser observado na Figura 3, com 16 amostras e  $k = 4$ . Assim, 25% dos dados são reservados para o teste (validação) e o restante (75%) fica destinado ao treinamento, isso ocorre de forma aleatória.

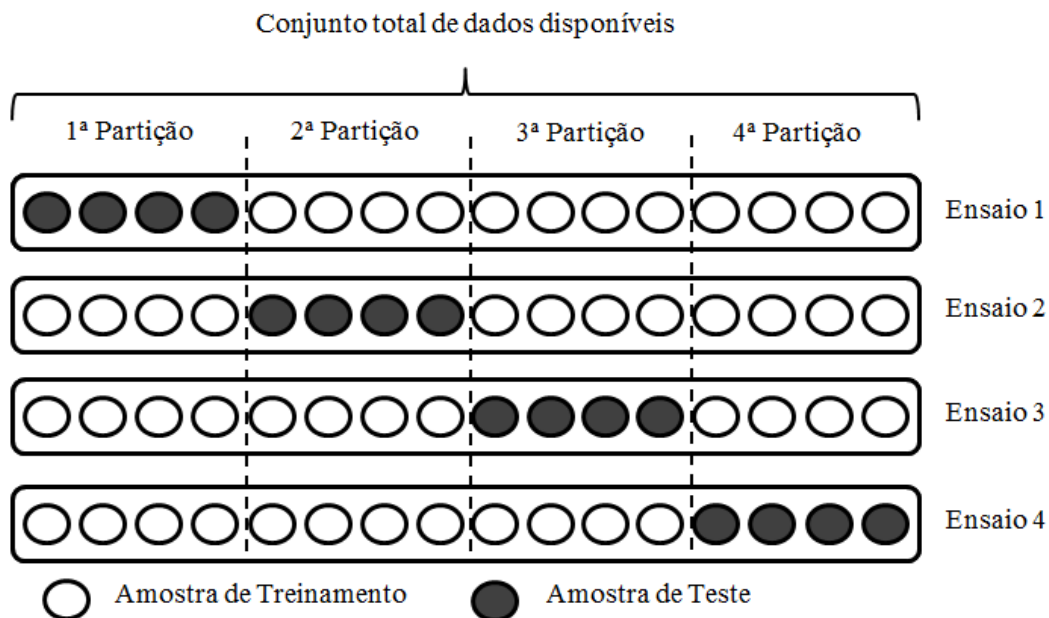


Figura 3 - Método de validação cruzada usando  $k$  partições.

Fonte: SILVA et al., 2010. Adaptado.

A divisão em  $k$  partições proporciona uma validação do modelo em um conjunto de dados diferentes do usado para adaptar os pesos sinápticos.

Após a seleção da topologia mais adequada, ocorrem os treinamentos da rede com essa topologia estipulada e espera-se que a RNA formada seja capaz de aproximar ao máximo as saídas a serem geradas, afim de adequadas aplicações. Quando se tem duas topologias de redes MLP que estão generalizando com o mesmo grau de precisão, a serem consideradas, deve-se selecionar aquela composta pela menor quantidade de neurônios, pois demonstra que ela foi capaz de extrair mais conhecimento (SILVA et al., 2010).

### 1.1.2 Fase de teste de uma RNA

A fase de teste, também conhecida como generalização, consiste em reproduzir saídas adequadas para entradas que não estavam presentes durante o treinamento (HAYKIN, 2001), utilizando-se o conjunto de teste para determinar a performance e a validação da RNA.

A capacidade de aprender por meio de exemplos e de generalizar a informação aprendida se torna uma importante característica das RNA, que é atrativa e leva a busca de solução de problemas complexos por meio das mesmas (BRAGA et al., 2007).

Depois das etapas de treino e teste define-se uma rede adequada (com erro satisfatório), que está pronta para receber um banco de dados desconhecido e realizar a predição (ou classificação, depende do interesse) da variável de saída pré determinada na etapa de validação ou aplicação (fase de operação). Para isto, a rede deverá ser utilizada apenas no modo progressivo - *feedforward*. Ou seja, novas entradas são apresentadas à camada de entrada, processadas nas camadas ocultas e os resultados são apresentados na camada de saída, como no treinamento, mas sem a retropropagação do erro.

Quando a RNA estiver sendo usada na etapa de aplicação, há a necessidade de se realizar instruções de pós-processamentos, de forma similar às normalizações efetuadas nos pré-processamentos dos dados. Nesta situação, executam-se operações de desnormalização a fim de converter as respostas dos neurônios de saída da rede para valores que representam os domínios reais da aplicação (SILVA et al., 2010). A Figura 4 exemplifica as fases de treinamento e operação das RNA.

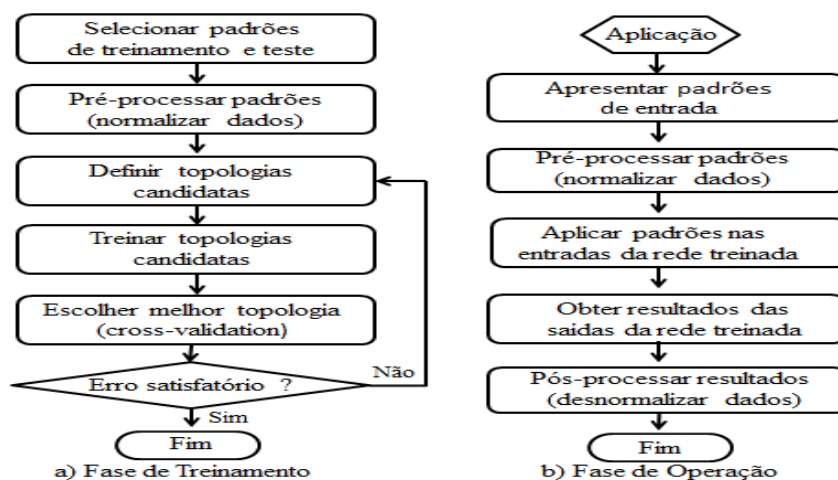


Figura 4 - Diagrama de blocos das fases de treinamento e operação.

Fonte: SILVA et al., 2010.



As potenciais áreas de aplicabilidade das RNA são: Aproximador universal de funções (problemas de aproximação de funções); Controle de processos; Reconhecimento e classificação de padrões; Agrupamento de dados (clusterização); Sistemas de previsão; Otimização de sistemas; Análise de séries temporais e Memórias associativas (JAIN et al., 1996; HAYKIN, 2001; BRAGA et al., 2007 e SILVA et al., 2010).

## **2. APLICAÇÕES DE RNA NA ÁREA FLORESTAL**

No ramo da Ciência Florestal, diversas questões podem ser resolvidas por meio de RNA, dentre elas a modelagem do volume de árvores, prognose da produção madeireira e não-madeireira, predição de altura, predição de biomassa, dentre outros, podendo empregar dados de inventário florestal (variáveis dendrométricas, por exemplo), variáveis edáficas, climáticas e outras.

Na área de Mensuração e Manejo Florestal, a predição se dá em diversos níveis, de árvores individuais a povoamentos; e em diferentes características, imprescindíveis ao manejo, como volume, perfil de tronco, distribuição de altura e diâmetro, perfil da casca e, até mesmo, perfil do cerne (GORGENS et al., 2014).

Ozçelik et al. (2010) afirmam que as redes neurais oferecem uma série de vantagens, incluindo a capacidade de detectar implicitamente relações não-lineares complexas entre variáveis de entrada e saída, o que é muito útil na modelagem do volume de árvores, por exemplo.

A técnica de RNA é amplamente utilizada em diversos países, em estudos realizados em florestas nativas ou plantadas. Como exemplos das aplicações de RNA no ramo florestal, segue uma listagem dos trabalhos de diversos autores, com diferentes interesses em relação à aplicação desta alternativa computacional.

Guan e Gerther (1991a; 1991b), utilizaram redes RBF (*Radial Basis Fuction*) para modelar e prever a sobrevivência de árvores de *Pinus*. Em relação à predição e projeção de sobrevivência, as estimativas geradas foram precisas.

Levine et al. (1996) concluíram que as RNA foram capazes de aprender a estrutura do solo a partir de dados de caracterização do mesmo, e mostraram uma maior capacidade de classificar os tipos de estrutura do solo do que os métodos lineares, mais simples.

Jensen et al. (1999) estimaram a idade de uma floresta de *Pinus* no Sul do Brasil utilizando RNA e dados de sensoriamento remoto e afirmaram que se usadas com cautela, as

RNA tem potencial para modelar com mais precisão alguns parâmetros biofísicos da floresta (como a idade), utilizando dados de sensores remotos.

Liczner e Nearing (2003) estudaram a erosão do solo em oito locais dos Estados Unidos por meio de RNA, e os resultados sugeriram a possibilidade de utilização de redes neurais para estimar a erosão do solo pela água.

Diamontopoulou (2005) comparou RNA com 5 modelos de regressão não-linear para estimar o volume de casca em pinus (*Pinus brutia* Ten.), em uma floresta nativa na Grécia, e comprovou a maior acurácia das estimativas pelas RNA em relação aos algoritmos de regressão não linear.

Scrinzi et al. (2007) utilizaram RNA para prever o número de árvores em pé em diferentes classes de diâmetro a curto e longo prazo, para várias espécies alpinas, na Itália. As RNA mostraram uma boa capacidade de generalização e efetivamente reproduziram a distribuição das árvores nas classes de diâmetro ao longo do tempo.

Silva et al. (2009) avaliaram a aplicação de redes neurais artificiais (MLP e RBF) para estimação do volume de madeira de eucalipto, comparando os resultados obtidos com o ajuste do modelo volumétrico de Schumacher e Hall por diferentes algoritmos. As RNA apresentaram boa adequação ao problema, sendo recomendada para previsão volumétrica da produção de florestas plantadas.

Gorgens et al. (2009) estimaram volume de árvores de eucalipto (*Eucalyptus* spp.) e teca (*Tectona grandis* L.f.) por meio de RNA, e os resultados mostraram que a modelagem em rede proporcionou considerável redução na quantidade de equações a serem manipuladas, pois permitiu a abordagem de diversos locais e espécies por uma única rede.

Ozcelik et al. (2010) estimaram o volume de fuste de diferentes espécies na Turquia, e encontraram resultados satisfatórios para as estimativas por RNA, sendo algumas vezes, melhores do que o modelo testado (equações de afilamento e tabelas de volume padrão existentes).

Binoti et al. (2012) apresentaram um modelo de distribuição diamétrica baseado em um modelo de Autômatos celulares unidimensionais e RNA para a simulação de desbaste, e mostraram que a metodologia pode ser utilizada para a projeção da distribuição diamétrica de povoamentos submetidos a desbastes, permitindo estimar distribuições diamétricas futuras com exatidão.

Binoti, et al. (2013) apresentaram um modelo de estimação da altura de povoamentos equiâneos por meio de RNA visando minimizar o custo do inventário florestal. Foram treinadas RNA para diferentes percentagens do número de alturas coletadas no campo. A

aplicação da metodologia permitiu reduzir consideravelmente o custo para a realização do inventário florestal, sem perda da precisão das estimativas.

Binoti, et al. (2013) propuseram construir e validar um modelo de estimação da altura de árvores de eucalipto com a utilização de RNA para dois cenários: quando há a introdução de um novo material genético e não existem informações sobre a relação hipsométrica deste; e quando já se conhece a tendência de crescimento em altura dos povoamentos implantados, obtida pela existência de medições em parcelas de Inventário Florestal Contínuo. Mostraram que pode-se diminuir significativamente a necessidade de aferição da altura em campo em clones recém- introduzidos no povoamento, levando à redução dos custos.

Castro et al. (2013) utilizaram RNA para modelar o crescimento e produção de povoamentos de eucalipto localizados no norte do Brasil, ao nível de árvore individual, e encontraram certa subestimação para o número de árvores sobreviventes. Porém, as estimativas de diâmetro, altura e volume por hectare foram encontradas com acurácia, mostrando que as RNA são uma alternativa viável para a modelagem do crescimento e da produção tradicional no setor florestal.

Binoti et al. (2014a) propuseram uma metodologia com a utilização de RNA para estimativa de volume de árvores de eucalipto com e sem casca, visando redução do número de árvores a serem cubadas durante o processo de geração de equações volumétricas. Os autores obtiveram resultados satisfatórios para a estimação do volume, possibilitando a redução dos custos para a construção de equações volumétricas.

Binoti et al. (2014b) desenvolveram e avaliaram a aplicação de RNA para a projeção de parâmetros da distribuição Weibull. Os modelos utilizando RNA apresentaram melhorias na dispersão gráfica dos resíduos, bem como das estatísticas avaliadas, mostrando-se superior aos modelos de regressão comumente utilizados.

Gorgens et al. (2014) testaram a influência de diferentes arquiteturas em RNA para estimativa de volume de árvores individuais. Concluíram que, para obter estimativas de volume por árvore de eucalipto, no estudo em questão, a rede neural deve ser construída com mais de 10 neurônios na primeira camada, e é recomendado o uso de mais de uma camada intermediária.

Castro et al. (2015) avaliaram a potencialidade de RNA para estimar a probabilidade de mortalidade que cada árvore tem entre dois períodos de medição de árvores individuais em um fragmento de floresta semidecídua. E concluíram que as RNA foram eficazes para prever a mortalidade das árvores.

Cordeiro et al. (2015) testaram três metodologias para estimar o volume de árvores de eucalipto, sendo estas o uso de todo o banco de dados de cubagem; utilizando somente 20% das árvores aleatoriamente, independente do clone; e utilizando 20% das árvores de cada clone; e chegaram a conclusão que as estimativas das RNA foram eficientes para as três metodologias, comprovando dessa forma a possibilidade de diminuir o número de árvores cubadas.

## 2.1. Estimativa de biomassa por meio de RNA

Foody et al. (2001) afirmaram que na maioria das vezes, o sensoriamento remoto é a única maneira prática de estimar a biomassa. Em uma floresta tropical na Ásia, os autores concluíram que as estimativas de biomassa por meio de sensoriamento remoto com auxílio das RNA, foram mais precisas quando comparadas com a biomassa medida em campo do que as estimativas oriundas de 230 índices de vegetação convencionais, incluindo o índice de vegetação mais utilizado, que é o NDVI (Índice de Vegetação por Diferença Normalizada).

Foody et al. (2003), investigaram a possibilidade de transferência das relações preditivas para a estimativa biomassa de floresta tropical por meio de imagens de satélite (Landsat TM) associadas às RNA em três ambientes (Brasil, Tailândia e Malásia). Três tipos de relação preditiva, com base em índices de vegetação, de regressão múltipla e redes neurais *feedforward*, foram desenvolvidos para estimar a biomassa em cada local. Quando estudado um local em específico, a RNA teve boa capacidade de predição, porém, foi evidente que a precisão (indicada pelo coeficiente de correlação), diminuiu quando uma relação foi transferido para um local diferente daquele em que foi desenvolvido.

Del Frate e Solimini (2004) usaram RNA para estimativa de biomassa florestal em diversos tipos florestais (de boreal a tropical) aplicando-as a imagens de satélite. Concluíram que os métodos baseados em RNA eram equivalentes aos métodos estatísticos de regressão linear e não linear para os dados estudados.

Muukkonen e Heikanen (2005) utilizaram imagens do satélite ASTER para estimar volume de povoamentos da floresta boreal e posteriormente converteram o volume da área para estimar a biomassa acima do solo usando fatores de expansão da biomassa. Técnicas de análise de regressão não-linear e redes neurais foram aplicados para desenvolver modelos para a previsão de biomassa e os erros de estimativa relativos (RMSEr) da biomassa aérea total dos povoamentos florestais foram de 44,7% e 41,0% utilizando análise de regressão

múltipla e redes neurais, respectivamente. Embora os erros de estimativa permaneceu grande, as previsões foram relativamente preciso em relação a estudos anteriores.

Schoeninger et al. (2008) utilizaram as RNA associadas ao procedimento de sensoriamento remoto para elaborar mapas temáticos para estimativas de biomassa e carbono orgânico armazenado no componente arbóreo de uma Floresta Ombrófila Densa, em Santa Catarina - SC e confirmaram que a aplicação de técnicas de RNA mostrou-se promissora na obtenção de estimativas na quantidade de biomassa arbórea.

Almeida et al. (2009) utilizaram redes neurais de Kohonen para segmentar e classificar as imagens. Para a estimativa do potencial energético de biomassa florestal na região amazônica, utilizaram redes neurais de função de base radial e sistema de informações geográficas, reduzindo os custos em relação a metodologia tradicional de inventário florestal.

Ferraz et al. (2014), da mesma forma que os autores anteriores, também utilizaram a metodologia integrada de sensoriamento remoto com RNA e estimaram os estoques de biomassa e carbono na parte aérea de um fragmento de Floresta Estacional Semidecidual Montana, em Viçosa - MG, por meio de imagens de satélite IKONOS II. As RNA apresentaram eficiência nas estimativas utilizando as 4 bandas espectrais.

Miguel et al. (2015), avaliaram a eficácia da aplicação de modelos de análise de regressão e RNA associadas às imagens do sensor LISS-III na predição do volume de madeira e biomassa acima do solo em área de cerradão no município de Palmas - TO. A área basal e os índices de vegetação foram utilizados como dados de entrada das RNA. Os resultados obtidos foram eficazes na estimativa do volume de madeira e biomassa, já que os valores reais não diferiram estatisticamente dos valores estimados pelos modelos de regressão e de RNA, ainda assim, as RNA foram mais acuradas.

Como pode ser observado, a estimativa de biomassa por meio de RNA associada à imagens de satélite vem aumentando, utilizando-se a tecnologia de redes neurais artificiais para extrair informações sobre biomassa a partir de imagens de satélite e posteriormente, inseri-las em uma aplicação desenvolvida em sistemas de informações geográficas. Porém, ainda é escassa a utilização de RNA para predição de biomassa florestal utilizando apenas dados provenientes de inventário, sem as informações de imagens de satélites.

### **3. MÉTODOS DE QUANTIFICAÇÃO DE BIOMASSA EM FLORESTAS**

Em ecossistemas florestais, a biomassa é definida segundo Brown (1997) como a quantidade total de material vegetal (matéria orgânica viva acima do solo) expressa em

toneladas de biomassa seca por unidade de área. A autora relata que a biomassa é uma consequência direta de todos os fatores bióticos e abióticos do ecossistema.

Para Sanquetta (2002) a biomassa florestal ou fitomassa contempla toda a biomassa existente na floresta ou apenas as árvores, sendo que no primeiro caso, os componentes de biomassa geralmente estimados são a biomassa viva horizontal acima do solo, a biomassa morta acima do solo (composta pela serapilheira e troncos caídos) e a biomassa abaixo do solo (raízes). Assim, a biomassa total é dada pela soma de todos estes componentes.

Wharton e Griffith (1998) consideram fontes de biomassa nas árvores, as cascas, ramos, folhagens, o sistema de toco-raiz; árvores abatidas e árvores mortas aproveitáveis. Para a biomassa total, adicionam a biomassa das plântulas, mudas e arbustos e outras plantas, constituindo a biomassa florestal.

As árvores acumulam em sua estrutura carbônica, elementos poluentes nocivos à qualidade de vida. Por esse motivo, cresce a cada dia, o interesse pelos estudos de biomassa e conteúdo de carbono em florestas. Estas estocam carbono tanto na biomassa acima como abaixo do solo e representam mais carbono do que atualmente existe em relação ao estoque na atmosfera (HOUGHTON, 1994).

Para os estudos de carbono em florestas naturais ou plantadas, um dos aspectos mais importantes é a variável biomassa, a qual precisa ser determinada ou estimada de forma mais confiável possível, para que se tenha consistência na quantificação do carbono fixado nos ecossistemas florestais mensurados (SILVEIRA et al., 2008).

Muitos métodos para quantificar a biomassa foram explorados durante as últimas décadas, mas não há definição do melhor método, visto a complexidade de obtenção de certos dados em florestas naturais principalmente. Os estudos para quantificação de biomassa florestal e carbono podem ser divididos em dois métodos: Métodos diretos ou determinação e Métodos indiretos ou estimativas (HIGUCHI e CARVALHO JÚNIOR, 1994; SANQUETTA, 2002).

### 3.1. Métodos diretos

Também conhecido como método destrutivo, o método direto consiste na determinação da biomassa, com uma medição real feita diretamente no campo, contando com a retirada de amostras de partes da vegetação. Essas amostras podem ser retiradas de qualquer dos componentes da floresta, estejam elas acima ou abaixo do solo, como amostras do sub-bosque, serapilheira, ou das várias partes das árvores e até mesmo de árvores inteiras. Neste

método, as árvores necessitam ser derrubadas e cubadas com representatividade em todas as classes de diâmetro. Higuchi et al. (1998) e Silveira et al. (2008) relatam que o método direto consiste na derrubada e pesagem de todas as árvores, para que posteriormente se possa fazer a extrapolação da amostra para a área total.

Pardé (1980) citado por Sanquetta (2002) relata que os métodos diretos de amostragem de biomassa podem ser divididos em duas grandes categorias: método da parcela e método da árvore individual. O método da parcela é realizado em uma área pré-determinada, havendo o corte e pesagem de todo o material vegetal de interesse para a determinação da biomassa, podendo ser implementado pelo procedimento do corte total (*harvest method*), que consiste em determinar toda a biomassa da floresta, cortando e pesando todas as frações (incluindo as raízes) passo a passo; ou amostragem em múltiplos estágios (*multi-stage sampling*) na qual cortam-se todos os indivíduos contidos na parcela pesando-se todos os caules. Para as demais porções, são feitas determinações apenas para alguns indivíduos estabelecendo uma relação quantitativa entre os dois grupos. Sobre o método da árvore individual o autor afirma que o mesmo é realizado a partir da seleção de uma árvore média (*mean tree method*), sendo comum o emprego da árvore de área seccional média, adquirida por meio de um inventário piloto. Após a definição desta árvore, a mesma é derrubada para determinação da biomassa de um número de indivíduos da amostra. Uma variação deste método é necessária quando envolve florestas com estrutura mais complexa. Nesse caso, é preciso conhecer a distribuição diamétrica dessa floresta para que um determinado número de árvores (abrangendo cada amplitude diamétrica existente) sejam derrubadas, levando em consideração todas as classes existentes na floresta.

Além do método de árvore individual descrito anteriormente, Ogawa e Kira (1977), citados por Silveira et al. (2008) apresentaram outra técnica para determinação de biomassa em árvores individuais chamada técnica do corte estratificado (*stratified clip technique*). Esse método consiste na execução do corte raso em um pequeno ponto amostral no interior da floresta a ser estudada, dividindo-se a parte de cima do solo em 10 ou mais estratos paralelos à superfície do solo, e todas as árvores dentro do ponto são cortadas em partes dentro do respectivo estrato, e pesadas as folhas, ramos e caule pertencentes a cada estrato separadamente.

Como exemplo de trabalhos encontrados na literatura utilizando-se métodos diretos para determinação da biomassa, têm-se Teixeira et al. (1994); Higuchi e Carvalho Júnior (1994); Higuchi et al. (1998); Teixeira e Oliveira (1999); Watzlawick et al. (2003, 2005); Carmo et al. (2004); Sanquetta et al. (2006); Cotta et al. (2008).

### 3.2. Métodos indiretos

Os métodos indiretos não requerem a retirada e destruição do material vegetal para a quantificação da biomassa. É gerada uma estimativa por meio de relações matemáticas, utilizando dados advindos de inventários florestais, para que se possa correlacionar a biomassa com alguma variável de fácil obtenção, ou utilizando dados de sensoriamento remoto. No emprego de um sistema de informação geográfica em estimativas de biomassa, utiliza-se geralmente uma ampla base de dados e mapas digitais de inventário, de população, clima, vegetação, solos e de topografia (SILVEIRA et al., 2008).

As quantificações de biomassa de forma indireta podem ser enquadradas de duas maneiras quando se trabalha em nível de campo. A primeira delas é utilizando dados de volume de árvores ou talhões, adquiridos em inventários florestais, e multiplicá-los por um fator ou fatores apropriados denominados fatores de biomassa (*BF*). Esses fatores convertem as estimativas de volume para estimativas de biomassa quando não é utilizado informações da densidade básica da madeira (SOMOGYI et al., 2006). Uma situação exemplo de uso dos *BF*, pode ser quando é necessário a estimativa total de biomassa, mas apenas dados de biomassa comercial estão disponíveis. Nesse caso, utiliza-se um fator de expansão (*BEF*), obtido pela razão da biomassa seca total acima do solo, para árvores com um diâmetro a 1,30m do nível do solo (*DAP*) mínimo de 10 cm, pela biomassa seca do volume inventariado ou comercial.

Se for levado em consideração a deterioração do ambiente natural, deve-se utilizar fatores de redução de acordo com Husch et al. (2003). Esse autores indicam que é necessário que estudos envolvendo o corte e pesagem de árvores amostra para determinar os pesos líquido e bruto de biomassa, sejam desenvolvidos, e assim, é possível estimar diretamente a biomassa das árvores amostradas sem usar o procedimento de conversão de volumes de inventário. Somogyi et al. (2006) alertam para o fato de que ao selecionar ou desenvolver um *BF*, deve-se tomar cuidado para que este seja um valor representativo para toda a população florestal. Os fatores de biomassa são altamente dependentes das condições locais, e a maioria dos que estão disponíveis na literatura são baseadas em estudos de caso em condições específicas, usando poucas árvores.

A segunda maneira de quantificar a biomassa de forma indireta é pelo uso de modelos que extrapolam as estimativas de biomassa, ao longo do tempo e/ou espaço a partir de dados obtidos por medições in situ; ou uso de sensoriamento remoto (levando em consideração as propriedades espectrais dos componentes da vegetação). A utilização dessa técnica em florestas heterogêneas se torna mais complexa devido à grande diversidade florística,



fisionômica e fenológica que esse tipo florestal apresenta. Em florestas plantadas, por possuírem apenas um gênero, na maioria das vezes, e serem inventariadas com periodicidade, essa complexidade tende a ser amenizada.

Segundo Koehler et al. (2002), na maioria dos casos, opta-se por ajustes de equações por meio de técnicas de regressão utilizando equações de volume pré estabelecidas para a tipologia estudada, advindos de dados de inventários. As estimativas podem ser realizadas por meio de relações empíricas entre a biomassa e outras variáveis e também, por meio da técnica de derivação do volume comercial e posterior extrapolação dos resultados (CHAVE et al., 2005; SOMOGYI et al., 2006, HENRY et al., 2010).

Ao estimarem o estoque de biomassa e carbono pelo método da derivação do volume comercial, Schneider et al. (2005), constataram a eficiência desse método em comparação às equações para estimativa de biomassa. Outra alternativa à estimativa de biomassa derivada da aplicação de equações de regressão, segundo Brown (1997), é utilizar um conjunto de dados de diâmetro (utiliza-se o diâmetro médio por classe para representá-la e o número de árvores em cada classe).

As florestas tropicais apresentam muitas espécies em um mesmo hectare e para Chave et al. (2005) essa característica dificulta o uso de um modelo de regressão específico por espécie, levando a necessidade de uso de modelos por grupos de espécies. Esses autores afirmam que as informações dendrométricas são extraídas de um pequeno número de árvores, que são derrubadas com uma pequena amplitude diamétrica, dessa forma não representa bem a floresta num todo. Isso pode explicar o porquê de dois modelos produzirem estimativas diferentes para um mesmo tipo florestal.

Wharton e Griffit (1998), corroborando com as informações, ressaltam que o volume, variável precursora para estimativa de biomassa, é obtido por meio de métodos que muitas vezes não definem adequadamente as condições de toda a floresta, portanto, têm aplicabilidade limitada para os tipos de avaliações exigidas atualmente pelos planejadores, gestores e pesquisadores dos recursos florestais. Para as estimativas de biomassa a partir de volume, pode ser incluída a variável densidade chamada de densidade básica (obtida por meio da divisão da massa seca pelo volume úmido), em busca de uma aproximação das condições que a madeira apresenta quando encontra-se no estado natural em uma floresta.

### 3.3. Divergências de opiniões sobre os métodos de quantificação de biomassa

Opiniões divergentes podem ser encontradas nos estudos envolvendo os métodos direto e indireto de quantificação de biomassa.

Brown et al. (1989) alertam que as estimativas advindas de métodos diretos, baseadas em dados de poucas parcelas, podem ser tendenciosas na seleção. Essa tendenciosidade pode ser devido ao fato da determinação da biomassa ser trabalhosa. E em função da dificuldade de repetição do trabalho, tende-se a se escolher uma área mais densa, mais homogênea e mais fácil de trabalhar. Por estas razões as estimativas baseadas em métodos diretos tendem, segundo estes autores, a subestimação.

Corroborando com esse pensamento, Higuchi et al. (1998) ressaltam que determinar a biomassa de cada árvore, pelo método direto é uma tarefa muito demorada e onerosa. E que por essa razão, recursos da análise de regressão para o desenvolvimento de modelos estatísticos, devem ser empregados para superar este problema, estimando a biomassa de árvores em pé.

Em contrapartida, Fearnside (1991) e Higuchi e Carvalho Júnior (1994), contestam as críticas feitas por Brown et al. (1989), aos métodos diretos. Segundo os autores, os métodos indiretos são mais tendenciosos e suas estimativas ficam muito abaixo de todos os valores já obtidos por meio dos métodos diretos.

Brown (1997) afirmou que o uso do método indireto, com equações de regressão, é mais vantajoso, pois as estimativas de biomassa são adquiridas sem a necessidade de se calcular a variável volume. A autora afirma ainda que, com relação a equações que necessitam de informações de volume a desvantagem é que geralmente estes não possuem dados de todas as classes de diâmetro. Isso ocorre porque a grande parte dos inventários florestais visa somente a parte comercial, sendo medidos os indivíduos com maiores diâmetros, desprezando-se assim, as árvores menores, que podem representar até 30% da biomassa de uma floresta.

Em concordância com a autora, Houghton (1994) ressaltou que as estimativas de biomassa não podem desconsiderar as árvores menores. O autor destaca também a importância da vegetação rasteira no solo e vegetação viva abaixo do solo (raízes), devendo-se incluir também a vegetação morta, tanto acima como abaixo do solo, em pé ou caída. A preocupação com a desconsideração dos componentes subterrâneos e mortos também é referida por Fearnside (1994).

Higuchi et al. (1998) afirmaram que para a região amazônica os modelos alométricos utilizando apenas o *DAP* como variável independente apresentam resultados tão consistentes quanto os modelos que utilizam também a altura. Relatam que muitas vezes a altura

mensurada em campo não é a real pois em florestas naturais, principalmente, têm-se muita dificuldade de mensura-la com precisão e os modelos com a ausência dessa variável se tornam mais apropriados.

As controvérsias são frequentes, entretanto, estudos utilizando os dois métodos conjuntamente são necessários para que as quantificações de biomassa sejam determinadas e estimadas de forma fidedigna (SANQUETTA e BALBINOT, 2004).

#### **4. BIOMASSA EM DIFERENTES COMPARTIMENTOS DA FLORESTA**

As florestas brasileiras estocam aproximadamente 117 milhões de toneladas de biomassa (acima e abaixo do solo; biomassa viva e morta). A Floresta Estacional Semidecidual possui 110,75 ton/ha de biomassa acima do solo e 20,76 ton/ha abaixo do solo (SFB, 2014).

A biomassa em uma floresta se encontra em todos os seus compartimentos, sendo eles: parte aérea das árvores (folhas, galhos, fuste), no sistema radicular, nos sub-bosques, na serapilheira ou material caído (incluindo folheto e madeira morta) e também na camada orgânica do solo (IPCC, 2006). Soares et al. (2011) compreendem como parte aérea das árvores o conjunto de galhos e folhas, o tronco (constituído pela madeira e pela casca) e os frutos e as flores, se presentes.

No início do desenvolvimento de uma floresta, há maior produção de biomassa na copa e no sistema radicular. Entretanto, com o passar do tempo, a medida que ocorre o desenvolvimento da floresta, a produção relativa de biomassa no tronco (componentes madeira e casca) aumenta enquanto na copa, folhas e ramos diminui de forma gradativa (ANDRAE, 1978; SCHUMACHER, 1996; SCHUMACHER e HOPPE, 1997). A maior concentração de biomassa na parte aérea das árvores, representa em média mais de 80% da biomassa acima do solo, e em geral, a maior parte da biomassa vegetal encontra-se na parte aérea das árvores de maior diâmetro (SCHUMACHER e HOPPE, 1997; SFB, 2014).

Diversos autores desenvolveram trabalhos considerando a biomassa nos diferentes compartimentos da floresta e conseguiram concluir em quais compartimentos há maior ou menor concentração dessa variável. A distribuição de biomassa em diferentes compartimentos da floresta não segue um padrão específico, podendo variar de acordo com as características das espécies e do ambiente (fatores edáficos e climáticos).

De acordo com Curlin (1970) citado por Watzlawick et al. (2005), geralmente, a biomassa acima do solo é distribuída na seguinte ordem: madeira do fuste > galhos > casca >

folhas. Em um estudo no semi-árido brasileiro, Drumond et al. (2008), considerando também a biomassa abaixo do solo, relatou que a distribuição da biomassa nos diferentes componentes arbóreos da maioria das espécies seguiu, esta ordem: lenho> raiz> galho> casca>folha.

A distribuição da biomassa nos diferentes órgãos da planta varia de espécie para espécie, e até mesmo em uma população com a mesma espécie. Barichello et al. (2005), em um povoamento de *Acacia mearnsii* De Wild., aos 8 anos de idade, encontraram uma produção de biomassa pelos órgãos da planta seguindo a ordem: madeira > raízes > galhos vivos > casca > galhos mortos > folhas. Em um outro estudo, com a mesma espécie, aos 9 anos de idade, Pereira et al. (1997) encontraram uma ordem diferente da distribuição de biomassa acima do solo: madeira > casca > galhos vivos > folhas > galhos mortos. Assim, comprova-se a variação na distribuição da biomassa nos diferentes compartimentos em uma árvore da mesma espécie, com diferentes idades.

Alguns trabalhos apresentam a distribuição da biomassa nos compartimentos da floresta em forma de porcentagem de biomassa.

Caldeira et al. (2004), ao estudar uma Floresta Ombrófila Mista Montana no Paraná, constataram que a biomassa nas raízes até 0,5 m de profundidade correspondeu a 25% do total da biomassa, valor presente entre o intervalo de 9,2 e 48%, encontrados em trabalhos realizados em florestas nativas em outras partes do mundo, o que confirma novamente a inexistência de padrões definidos para distribuição de biomassa.

Higuchi et al. (1998) , em uma Floresta Tropical Amazônica, estimaram a biomassa acima do solo com os troncos correspondendo a 65,6% e a copa a 34,4% (dividida em galhos grossos (diâmetro >1,0 cm) com 17,8%, galhos finos com 14,5%, folhas com 2,03% e flores/frutos com 0,01%).

Para uma floresta nativa do sul do Brasil, Vogel et al. (2006) concluíram que a madeira do fuste correspondeu a 43,4% do total, a casca do fuste a 5,4%, as folhas a 2,4% e os galhos a 48,8%.

Socher et al. (2008) estimaram a biomassa acima do solo para uma área de Floresta Ombrófila Mista e chegaram à conclusão que a madeira representou 52,8% do total, os galhos 40,3%, a casca 4,4% e as folhas 2,1%, sendo o restante distribuído entre frutos, sementes, epífitas, etc.

Amaro et al. (2013) estudando o estoque volumétrico, de biomassa e de carbono em uma Floresta Estacional Semidecidual, relatou que o fuste com casca contribuiu com 80,30% do volume total e a copa com 19,70%.O total de biomassa encontrado foi igual a  $227,40 \pm$

77,81 t ha<sup>-1</sup>. Do total de biomassa, 79,8% estavam acima do solo; 15,1% nas raízes e 5,1% na serapilheira.

Considerando povoamentos de uma única espécie, Hoppe et al. (2006) obtiveram os valores de 4,3% folha, 0,4% fruto, 25,9% galhos, 4,4% casca, 46,5% madeira e 18,6% raiz para um povoamento de *Platanus acerifolia* (Aiton) Willd. Para *Nectandra grandiflora* Nees, Vieira et al. (2009) encontraram, em média, para folhas, galhos, raiz e fuste respectivamente, 2,9, 24,5, 13,8 e 58,8% da biomassa de uma árvore. Mognon et al. (2015) estudando a alocação e modelagem de biomassa em *Dendrocalamus asper* (Schult. & Schult. f.) Backer ex K. Heyne, encontraram a maior fração da biomassa na parte aérea, com 86%, sendo 64% para o compartimento colmo, 16% para os galhos e 6% para as folhas. Os rizomas representaram 14% da biomassa total.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. C.; BARROS, P. L. C; MONTEIRO, J. H. A; ROCHA, B. R. P. Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing, **IEEE Latin America Transactions**, Piscataway, v. 7, n. 1, p. 27-32, 2009.

AMARI, S.; MURATA, N.; MULLER, K. R.; FINKE, M.; YANG, H. Statistical theory of overtraining – Is cross-validation asymptotically effective? **Advances in Neural Information Processing Systems**, v. 8, p. 176-182, 1996.

AMARO, M. A.; SOARES, C. P. B.; SOUZA de, A. L.; LEITE, H. G.; SILVA da, G. F. Estoque volumétrico de biomassa e de carbono em uma Floresta Estacional Semidecidual em Viçosa, Minas Gerais. **Revista Árvore**. Viçosa - MG, v. 37, n. 5, p. 849-857, 2013.

ANDRAE, F. H. **Ecologia Florestal**. Santa Maria: UFSM, 1978. 230 p.

ARTERO, A. O. **Inteligência Artificial** - Teoria e prática. Ed. Livraria da Física, 2009. 230p.

BARICHELO, L. R.; SCHUMACHER, M. V.; VOGEL, H. L. M. Quantificação da biomassa de um povoamento de *Acacia mearnsii* De Wild. na região sul do Brasil. **Ciência Florestal**. Santa Maria - RS, v. 15, n. 2, p. 129-135, 2005.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**. Viçosa - MG, v. 36, n. 5, p. 931-939, 2012.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias**. Recife - PE, v. 8, n. 1, p. 125-129, 2013.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**. Viçosa - MG, v.37, n.4, p.639-645, 2013.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H.G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L.; Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**. Viçosa - MG, v. 38, n. 2, p. 283-288, 2014a.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; SILVA, A. A. L.; PONTES, C. Utilização de redes neurais artificiais para a projeção da distribuição diamétrica de povoamento equiâneos. **Revista Árvore**. Viçosa - MG, v. 38, n. 4, p. 747-754, 2014b.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2 ed. Rio de Janeiro: LTC, 2007.

BROWN, S.; GILLESPIE, A. J. R.; LUGO, A. E. Biomass estimation methods for Tropical Forests with applications to forest inventory data. **Forest Science**. Lawrence, v. 35, n. 4, p. 881 - 902, 1989.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. Roma, Itália: **FAO Forestry Paper**. 134. 1997. Disponível em <[Http://www.fao.org/docrep/w4095e/w4095e00.Htm](http://www.fao.org/docrep/w4095e/w4095e00.Htm)>. Acesso em: 24/04/2015.

CALDEIRA, M. V. W.; SOARES, R. V & WATZLAWICK, L.F. Estimativa de biomassa em espécies arbóreas da Floresta Ombrófila Mista Montana – General Carneiro-PR. **Biomassa & Energia**. Viçosa - MG, v. 1, n. 3, p. 291-310. 2004.

CARMO, C. A. F. de S. do; KINDEL, A.; ALVARENGA, A. de P.; MOTTA, P. E. F.; LIMA, J. A. de S.; TÔSTO, S. G.; MENEGUELLI, N. do A. **Comparação de biomassa e estoque de carbono entre os clones de seringueira IAN 837 e RRIM 600, plantados em solos da zona da mata, Minas Gerais**. Rio de Janeiro. 4p (Embrapa Solos. Circular Técnica, 26), 2004.

CASTRO, R. V. O.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L.; NOGEIRA, G. S.; MARTINS, F. B. Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. **International Scholarly Research Notices**. 12 p. 2013.

CASTRO, R. V. O.; SOARES, C. P .B.; LEITE, H. G.; SOUZA, A. L.; MARTINS, F. B.; NOGUEIRA, G. S.; OLIVEIRA, M. L. R. Artificial Neural Networks Effectiveness to Estimate Mortality in a Semi-Deciduous Seasonal Forest. **Australian Journal of Basic and Applied Sciences**, v. 9(5) p.435-444 , 2015.

CHAVE, J.; ANDALO, C.; BROWN, S.; CAIRNS, M. A. C.; CHAMBERS, J. Q.; EAMUS, D.; FÖLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T.; LESCURE, J.-P.; NELSON, B. W.; OGAWA, H.; PUIG, H.; RIERA, B.; YAMAKURA, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**. Berlin, v. 145, p. 87 - 99, 2005.

CORDEIRO, M. A.; PEREIRA, A. R. S. dos; BINOTI, D. H. B.; BIONTI, M. L. M. S.; LEITE, H. G. Aplicação de redes neurais artificiais para quantificação volumétrica de árvores

de eucalipto no Estado do Amapá. **Revista de biologia e ciências da terra**. São Cristóvão - SE, v. 15 n 1 , p. 48 -58, 2015.

COTTA, M. K.; JACOVINE, L. A. G.; PAIVA, H. N. de; SOARES, C. P. B.; VIRGENS FILHO, A. de C.; VALVERDE, S. R. Quantificação de biomassa e geração de certificados de emissões reduzidas no consórcio seringueira-cacau. **Revista Árvore**. Viçosa - MG, v. 32, n 6, p. 969-978, 2008.

CURLIN, J. W. Nutrient cycling as a factor in site productive and forest fertilization. In: YOUNGBERG, C. T.; DAVEY T. **Tree growth and forest soils**. Oregon: Oregon State University Press, 1970. p. 313-326.

DEL FRATE, F.; SOLIMINI, D. On Neural Networks Algorithms for Retrieving Forest Biomass from SAR Data. **IEEE Transactions on Geoscience and Remmote Sensing**. v. 42, n. 1, p.24 -34, 2004.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**. Amsterdam, v. 10, p. 235 - 244, 2005.

DRUMOND, A. N.; PIRES, I. E.; OLIVEIRA, V. R. de; OLIVEIRA, A. R. de; ALVAREZ, I. A. Produção e distribuição de biomassa de espécies arbóreas no semi-árido brasileiro. **Revista Árvore**. Viçosa - MG, v. 32, n. 4, p. 665-669, 2008.

FEARNSIDE, P. M. Greenhouse gas contributions from deforestation in Brazilian Amazonia. In: LEVINE, J. S. (Ed.) **Global Biomass Burning: Atmospheric Climatic and Biospheric Implications**. Boston: MIT, 1991. p. 92-105.

FERRAZ, A. S.; SOARES, V. P.; SOARES, C. P. B.; RIBEIRO, C. A. A. S.; BINOTI, D. H. B.; LEITE, H. G. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**. Seropédica - RJ, v. 21, n. 3, 2014.

FOODY, G. M; CUTLER, M. E; MCMORROW, J; PELZ, D; TANGKI, H; BOYD, D. S; DOUGLAS, I. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology and Biogeography**, v. 10, n. 4, p. 379-387, 2001.

FOODY, G. M.; BOYD, D. S.; CLUTER, M. E. J. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**. Ottawa, v. 85, p. 463-474, 2003.

GORGENS, E. B.; LEITE, H. G; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**. Viçosa - MG, v. 33, n. 6, p. 1141-1147, 2009.

GORGENS, E. B.; LEITE, H. G; SANTOS, H. N.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**. Viçosa - MG, v. 38, n. 2, p. 289-295, 2014.

GUAN, B. T ;GERTNER, G.Z. Using a paralalled distributed processing system to model individual tree mortality. **Forest Science**. Lawrence, v. 37, n. 3, p. 871-885, 1991a.

GUAN, B. T ;GERTNER, G.Z. Modeling red pine tree survival with an artificial neural network. **Forest Science**. Lawrence, v. 37, n. 5, p. 1429-1440, 1991b.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEBB, D. O. **The Organization of Behavior**. John Wiley & Sons, New York, 1949.

HENRY, M.; BESNARD, A.; ASANTE, W. A.; ESHUN, J.; ADU-BREDU, S.; VALENTINI, R.; BERNOUX, M.; SAINT-ANDRÉ, L. Wood density, phytomass variations within and among trees, and allometric equations in a tropical rainforest of Africa. **Forest Ecology and Management**. Amsterdam, v. 260, p. 1375-1388, 2010.

HIGUCHI, N.; CARVALHO JÚNIOR, J. A. Fitomassa e conteúdo de carbono de espécies arbóreas da Amazônia. In: SEMINÁRIO EMISSÃO x SEQUESTRO DE CO<sub>2</sub> – UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL, 1994, Rio de Janeiro. **Anais...** Rio de Janeiro: CVRD, 1994. p. 125-145.

HIGUCHI, N. ; SANTOS, J. dos; RIBEIRO, R. J.; MINETTE, L.; BIOT, Y. Biomassa da parte aérea da vegetação da Floresta tropical úmida de terra-firme da Amazônia Brasileira. **Acta Amazonica**, Manaus - AM, v. 28, n. 2, p. 153-166, 1998.

HOPPE, J. M.; WITSCHORECK, R.; SCHUMACHER, M. V. Estimativa de biomassa em povoamento de *Plantanus x acerifolia* (Aiton) Wild. estabelecido no município de Dom Feliciano, RS. **Ciência Florestal**. Santa Maria - RS, v. 16, n. 4, p. 463 - 471, 2006.

HOPFIELD, J. J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. **Proceedings of National Academy of Sciences**, v. 79, p. 2554 - 2558, 1982.

HOUGHTON, R. A. As florestas e o ciclo de carbono global: armazenamento e emissões atuais. In: SEMINÁRIO EMISSÃO x SEQUESTRO DE CO<sub>2</sub> – UMA NOVA OPORTUNIDADE DE NEGOCIOS PARA O BRASIL, 1994, Rio de Janeiro. **Anais...** Rio de Janeiro: CURD, 1994. p. 38-76.

HUSCH, B.; MILLER, C. I.; BEERS, T. W. **Forest mensuration**. 3.ed. New York: Jwiley e Sons, 2003. 443 p.

IPCC – Intergovernmental Panel on Climate Change. **Guidelines for National Greenhouse Gas Inventories: Agriculture, forestry and other land use**. Japan: Institute for Global Environmental Strategies (IGES), 2006.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

JENSEN, J. R ; QIU, F. ; JI, M. Predictive modeling of coniferous forest age using statistic and artificial neural network approaches applied to remote sensor data. **International Journal of remote sensing**, v. 20, n.14, p. 2805-2822, 1999.



KOEHLER, H. S.; WATZLAWICK, L. F.; KIRCHNER, F. F. Fontes e níveis de erros nas estimativas do potencial de fixação de carbono. In: SANQUETA, C. R. et al. (Eds.). **As florestas e o carbono**. Curitiba. 2002. p. 251-264.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **International Joint Conference on AI**. [S.l.: s.n.], 1995. p. 1137–1145.

LEVINE, E. R.; KIMES, D. S.; SIGILLITO, V. G. Classifying soil structure using neural networks. **Ecological Modelling**. Amsterdam, v. 92, n.1, p.101–108, 1996.

LICZNAR, P. ; NEARING, M. A. Artificial neural networks of soil erosion and runoff prediction at the plot scale. **Catena**, v.51, p. 89-114, 2003.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 5:115-133, 1943.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; MATRICARDI, E. A. T.; VALE, A. T.; PEREIRA, R. S. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa agropecuária brasileira**. Brasília - DF, v.50, n. 9, p. 829-839. 2015.

MINSKY, M.; PAPERT, S. **Perceptrons**: An introduction to computational geometry. MIT Press, Massachusetts, 1969.

MOGNON, F. A. L. R.; SANQUETTA, C. R.; DALLA CORTE, A. P.; NOVAES, A. B.; BLUM, C. T. Alocação e modelagem da biomassa em *Dendrocalamus asper*. **Floresta**. Curitiba - PR, v. 45, n. 1, p. 1 - 10. 2015.

MUUKKONEN, P.; HEISKANEN, J. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. **Remote Sensing of Environment**. Ottawa, v. 99, p. 434 - 447, 2005.

OGAWA, H. & KIRA, T. Primary Productivity of Japanese Forests. In: **Productivity of terrestrial Communities**, v. 16. p.15-21, Tokyo, 1977.

OZÇELIK, R.; DIAMANTOPOLOU, M. J.; BROOKS, J. R.; WIANT JR, H. V.; Estimating tree bole volume using artificial neural network models for four Species in Turkey. **Journal of Environmental Management**. v. 91, p. 742-753, 2010.

PARDÉ, J. Forest biomass. In: **Forestry Abstract Review Article**. França: Station de Silviculture et de Production, Centre National de Recherches Forestieres, v. 41, p. 349-352, 1980.

PEREIRA, J. C.; SCHUMACHER, M. V.; HOPPE, J. M.; CALDEIRA, M. V. W.; SANTOS, E. M. dos. Produção de biomassa em um povoamento de *Acacia mearnsii* De Wild. no Estado do Rio Grande do Sul. **Revista Árvore**. Viçosa - MG, v. 21, n. 4, p. 521-526, 1997.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In RUMELHART, D. E. and MCCLELLAND, J. L., editors, **Parallel**

**Distributed Processing:** Explorations in the Microstructure of Cognition. Volume 1: Foundations, MIT Press, Cambridge, MA, 1986.

RUSSEL, S.; NORVING, P. **Inteligência Artificial**. 2a. ed. Rio de Janeiro: Elsevier, 2004. 950p.

SANQUETTA, C.R.; BALBINOT, R. Metodologias para determinação de biomassa florestal. In: SANQUETTA, C.R.; BALBINOT, R.; ZILIOOTTO, M.A. (Org.). **Fixação de carbono:** atualidades, projetos e pesquisas. Curitiba: UFPR. 2004, p. 77 - 93.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINO, T. R.; ZILIOOTTO, M. A. B.; GOMES, F. S. **As florestas e o carbono**. Curitiba, Universidade Federal do Paraná, 2002, p. 119 - 140.

SANQUETTA, C. R.; CORTE, A. P. D.; BALBINOT, R.; LEAL, M. C. B S. ; ZILIOOTTO, M. A. B. Proposta metodológica para quantificação e monitoramento do carbono estocado em florestas plantadas. In: SANQUETTA, C. R. ; ZILIOOTTO, M. A. B.; CORTE, A. P. D. **Carbono:** Desenvolvimento tecnológico, aplicação e mercado global. Curitiba, Universidade Federal do Paraná, 2006, p. 240 - 265.

SCHNEIDER, P. R.; FINGER, C. A. G.; GIACOMELLI SOBRINHO, V.; SCHNEIDER, P. S. P. Determinação indireta do estoque de biomassa e carbono em povoamentos de acácia-negra (*Acacia mearnsii* De Wild). **Ciência Florestal**. Santa Maria - RS, v. 15, n. 4, 2005

SCHOENINGER, E. R.; KOEHLER, H. S.; BOTELHO, M. F.; WATZLAWICK, L. F.; OLIVEIRA, P. C. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa. **Ambiência**. Guarapuava - PR, v.4 n.2, p.179-195, 2008.

SCHUMACHER, M.V.; HOPPE, J.M. **A complexidade dos ecossistemas**, Porto Alegre: Editora Pallotti. 1997.

SCHUMACHER, M. V. Ciclagem de nutrientes como base da produção sustentada em ecossistemas florestais. In: SIMPÓSIO SOBRE ECOSSISTEMAS NATURAIS DO MERCOSUL : O AMBIENTE DA FLORESTA, 1996, Santa Maria. **Anais...** Santa Maria: UFSM/CEPEF, 1996. p. 65-77.

SCRINZI, G.; MARZULLO, L.; GALVAGNI, D. Development of a neural network model to update forest distribution data for managed alpine stands. **Ecological Modelling**. Amsterdam, v. 206, p. 331-346, 2007.

SERVIÇO FLORESTAL BRASILEIRO (SFB). **Estoque das Florestas:** Sistema Nacional de Informações Florestais. Brasília: SFB, 2014. 4 p.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI J. M.; LEITE H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**. Viçosa - MG, v. 33, n. 6, p.1133-1139, 2009.

SILVA, I. N. da; SPATTI, D. H; FLAUZINO, R. A. **Redes Neurais Artificiais:** para engenharia e ciências aplicadas. Ed. Artliber – SP, Universidade de São Paulo. 2010. 399p

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**. Curitiba - PR, v. 38, n. 1, p. 185 - 206, 2008.

SOARES, C. P. B.; PAULA NETO, F.; SOUZA, A. L. **Dendrometria e Inventário Florestal**. 2.Ed. Viçosa, MG: Editora UFV, 2011. 272p.

SOCHER, L. G.; RODERJAN, C. V.; GALVÃO, F. Biomassa aérea de uma Floresta Ombrófila Mista Aluvial no município de Araucária (PR). **Floresta**. Curitiba - PR, v. 38, n. 2, p. 245 - 252, 2008.

SOMOGYI, Z.; CIECIALA, E.; MAKIPAA, R.; MUUKKONEN, P.; LEHTONEN, A.; WEISS, P. Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, v. 126, n. 2, p. 197 - 207, 2006.

STONE, M. Cross-validation: A review. *Mathematische Operations forschung Statistis chen, Serie Statitics*, v. 9, p. 127-139. 1978.

TEIXEIRA, L. B.; BASTOS, J. B.; OLIVEIRA, R. F. de Biomassa vegetal em agroecossistema de seringueira consorciada com cacaueiro no nordeste paraense. Belém: **Embrapa-CPATU**, 1994. 15 p.

TEIXEIRA, L. B.; OLIVEIRA, R. F. de Biomassa vegetal e carbono orgânico em capoeiras e agroecossistemas no nordeste do Pará. Boletim: **Embrapa Amazônia Oriental**, 1999. 21 p.

VALENÇA, M. **Aplicando Redes Neurais**: Um guia completo. Olinda, PE. Ed. do Autor, 2005. 284p.

VALENÇA, M. **Fundamentos das redes neurais**: exemplos em Java. 2. ed. rev. ampl. Olinda, PE: Livro rápido. 2010. 386 p.

VIEIRA, G.; SANQUETTA, C. R.; BARBEIRO L. S. S. Estoque individual de biomassa e carbono em *Nectandra grandiflora* Nees (CANELA - AMARELA). **Floresta**. Curitiba - PR, v. 39, n. 3, p. 547 - 554, 2009.

VOGEL, H. L. M.; SCHUMACHER, M. V.; TRUBY, P. Quantificação da biomassa em uma Floresta Estacional Decidua em Itaara, RS, Brasil. **Ciência Florestal**. Santa Maria - RS, v. 16, n. 4, p. 419 - 425, 2006.

WATZLAWICK, L. F.; SANQUETTA, C. R.; ARCE, J. E.; BALBINOT, R. Quantificação de biomassa total e carbono orgânico em povoamentos de *Araucaria angustifolia* (Bert.) O. Kuntze no sul do estado do Paraná, Brasil. **Revista Acadêmica: ciências agrárias e ambientais**. Curitiba - PR, v. 1, n. 2, p. 63 - 68, 2003.

WATZLAWICK, L. F.; SANQUETTA, C. R.; CALDEIRA, M. V. W. Estoque de carbono orgânico e biomassa em *Pinus taeda* L. **Biomassa & Energia**. Viçosa - MG, v. 2, n. 1, p. 7-17, jan./mar. 2005.

WHARTON, H. E.; GRIFFITH, M. D. Estimating total forest biomass in maine, 1995. Northeastern Research Station. Resource Bulletin. NE-142. **USDA Forest Service**. 1998.

## **CAPÍTULO 2 - ESTIMATIVA DE BIOMASSA EM FLORESTA ESTACIONAL SEMIDECIDUAL POR MEIO DE REDES NEURAIIS ARTIFICIAIS**

### **1. INTRODUÇÃO**

Com o aumento da demanda de alternativas que visem o controle das emissões atmosféricas de dióxido de carbono ( $\text{CO}_2$ ), o interesse por pesquisas de biomassa e conteúdo de carbono nas florestas cresce a cada dia. Esse crescimento se dá devido ao papel indiscutível das florestas em reduzir os impactos ambientais do efeito estufa e às suas implicações nas mudanças climáticas (SCHROEDER, 1992; SANQUETTA, 2002), já que as árvores acumulam, em sua estrutura carbônica, elementos poluentes nocivos à qualidade de vida, armazenando em sua biomassa e no solo, mais carbono do que o existente na atmosfera (DIXON et al., 1994; GRACE, 2004; SILVEIRA et al., 2008). Desta forma, estudos que quantifiquem com acurácia a biomassa presente nas florestas são importantes para que haja maior compreensão do equilíbrio de entrada e saída de  $\text{CO}_2$  do ambiente.

Os estudos para quantificação de biomassa florestal podem ser divididos em dois métodos: métodos diretos e métodos indiretos (HIGUCHI e CARVALHO JÚNIOR, 1994; SANQUETTA, 2002). O método direto (destrutivo) implica, necessariamente, em derrubar árvores-amostra para obtenção dos dados (SOARES et al., 2011), podendo ser baseado em indivíduo médio, para plantios ou em unidade de área, parcelas, para florestas naturais. Esse método produz estimativas de biomassa confiáveis, entretanto, necessita de maior investimento financeiro e tempo para as coletas (BROWN et al., 1989; FEARNSIDE, 1991). O método indireto consiste em correlacionar a biomassa com alguma variável de fácil obtenção e que não requeira a destruição do material vegetal (SILVEIRA et al., 2008).

O método indireto utiliza dados originados de inventários florestais ou dados de sensoriamento remoto para a estimativa de biomassa, por meio de relações quantitativas ou matemáticas (SILVEIRA et al., 2008; MOGNON et al., 2013). As metodologias indiretas atuais mais utilizadas para o cálculo de biomassa realizam o ajuste de equações por meio de técnicas de regressão.

Silveira et al. (2008) chamaram atenção para a extrapolação do uso de equações alométricas, uma vez que diferentes ambientes são dominados por diferentes espécies, podendo levar à diminuição da precisão das estimativas, ao usar uma equação inadequada para o local.

Uma limitação dos métodos indiretos atuais para estimativa de biomassa é a dificuldade de adição de diversas variáveis qualitativas ao modelo, como fitofisionomias, qualidade de copa, infestação de cipós, dentre outras. Técnicas mais recentes, conhecidas como Redes Neurais Artificiais (RNA), baseadas na capacidade de mapeamentos não lineares e aprendizagem por meio de exemplos, têm sido usadas com sucesso nas mais diversas áreas, sendo capazes de contornar essa limitação.

Consideradas sistemas computacionais, baseados nos sistemas biológicos, as RNA são constituídas por unidades de processamento simples (neurônios artificiais), conectadas entre si para desempenhar uma tarefa determinada previamente, armazenando conhecimento experimental (aprendizagem) e tornando-o disponível para uso, fenômeno conhecido como generalização (BRAGA et al., 2000; HAYKIN, 2001; BRAGA et al., 2007).

As RNA se destacam por serem bastante flexíveis e de fácil adaptabilidade a diferentes situações e amostras. A capacidade de aprender por meio de exemplos e de generalizar a informação aprendida torna essa técnica atrativa, constituindo uma abordagem válida, como alternativa para a modelagem de ecossistemas biológicos dinâmicos e complexos, como as florestas (SCRINZI et al., 2007). No caso de florestas naturais, em que a diversidade e complexidade biológica é ainda mais acentuada, as RNA são promissoras, por possibilitarem a adição de variáveis qualitativas (categóricas) que podem permitir maior representatividade da realidade da área e levar à estimativas mais precisas para a variável de interesse.

## 2. OBJETIVOS

O objetivo desse trabalho foi quantificar a biomassa arbórea aérea de um fragmento de floresta Estacional Semidecidual em Minas Gerais - MG utilizando redes neurais artificiais.

Objetivou-se testar as seguintes hipóteses:

- $H_{01}$  = A utilização das variáveis contínuas ‘Densidade básica da madeira’, ‘Diâmetro a 1,30 do nível do solo’, ‘Volume com casca’, ‘Altura total ou altura de fuste’ resultam em estimativas confiáveis de biomassa da parte aérea, por meio de RNA.

$H_{A1}$  = Não  $H_{01}$ .

- $H_{02}$  = A adição das variáveis categóricas ‘fitofisionomia, infestação de cipó, qualidade de copa e coeficiente de De Liocourt’ combinadas ou não, à entrada da RNA com variáveis contínuas, influenciam na estimativa de biomassa da parte aérea.

$H_{A2}$  = Não  $H_{02}$ .

### 3. MATERIAL E MÉTODOS

#### 3.1. Caracterização da área de estudo

O estudo foi realizado em quatro fragmentos de Mata Atlântica no estado de Minas Gerais, que apresentam duas fitofisionomias e características climáticas distintas. As informações das áreas estão presentes na tabela 1. Os fragmentos amostrados foram reunidos em uma área de estudo para as análises. Essa decisão está associada a possibilidade de ajuste de uma única rede para realizar as estimativas, que possa abranger toda a área abordada.

Tabela 1 – Caracterização das áreas de estudo

Município	Projeto	Parcelas	Fitofisionomia	Clima (Köppen)	Temperatura (°C)		Ppt	Área (ha)
					Mín.	Máx.		
Caratinga	Lagoa do Piau (Mata 1)	16	Floresta Estacional Semidecidual Submontana	Aw - Clima tropical com estação seca	19,1	28,3	1.374	256,94
	Lagoa do Piau (Mata 2)	6						36,22
Coronel Fabriciano	São José	12	Floresta Estacional Semidecidual Montana	Cwb - clima temperado húmido com Inverno seco e Verão temperado	16,5	27,2	1.193	43,00
Guanhães	Cachoeira das Pombas	20		Cwa - clima temperado húmido com Inverno seco e Verão quente	18,2	29,6	1.113,8	161,6

Fonte: GASPAR, 2014, em que: Ppt = precipitação em mm.ano<sup>-1</sup>.

O projeto Lagoa do Piau é constituído por áreas de reserva legal e está dividido em duas partes (Mata 1 e Mata 2) devido ao fato de estarem separadas por uma região alagada.

### 3.2. Coleta e processamento de dados

Foram inventariadas em 2012, 54 parcelas de 0,05 ha ( $10 \times 50$  m), amostradas sistematicamente de modo que a amostra representasse todos os trechos dos fragmentos estudados, perfazendo um total de 2,7 ha de amostra.

Foram coletadas as seguintes informações em todas as árvores com diâmetro à 1,30 m do nível do solo ( $DAP$ )  $\geq 5$  cm: nome científico das espécies; circunferência a 1,30 m do nível do solo ( $CAP$ ), em centímetros; e alturas de fuste ( $Hf$ ) e total ( $Ht$ ), em metros. Também foi determinada a classificação da fitofisionomia, da qualidade das copas das árvores e infestação de cipós nas árvores.

A fitofisionomia foi classificada de acordo com o tipo de vegetação presente na área de estudo: Floresta Estacional Semidecidual Montana e Floresta Estacional Semidecidual Submontana (IBGE, 2012).

A qualidade de copa foi avaliada de acordo com Souza e Soares (2013):

- 1 - Boa (Copa inteira e bem distribuída);
- 2 - Regular (Copa com alguns galhos quebrados);
- 3 - Inferior (Copa com mais da metade dos galhos quebrados) .

Quanto a infestação de cipós, classificada em presença/ausência e local de ocorrência, a árvore recebeu uma das seguintes avaliações de acordo com Souza e Soares (2013) :

- 1 - Nenhum cipó;
- 2 - Cipós somente no tronco;
- 3 - Cipós somente na copa;
- 4 - Cipós no tronco e na copa.

Para a amostragem do tronco e para a determinação das densidades básicas da madeira, foram consideradas as espécies que possuíam no mínimo cinco indivíduos e representavam maiores percentuais de volume total, já que a biomassa está diretamente relacionada com a contribuição volumétrica de cada espécie.

Para cada espécie selecionada foram escolhidos aleatoriamente, nas parcelas de inventário, cinco indivíduos do estrato arbóreo para coletas de madeira pelo método do trado. A tradagem do tronco foi realizada na profundidade correspondente à metade do diâmetro do tronco, à altura de 1,30 m do nível do solo, na posição horizontal. Essa amostragem contemplou apenas indivíduos adultos, isto é, indivíduos com  $DAP \geq 5$  cm.

A determinação da densidade básica da madeira seguiu as metodologias de Vital (1984) e da ABNT (1997). As amostras de madeira foram saturadas pelo método de imersão, baseado no Princípio de Arquimedes, em que a perda aparente de peso de um corpo imerso é igual ao peso do líquido deslocado por ele. Assim, foi determinado o volume das amostras de madeira, e as mesmas foram secas em estufa de circulação forçada a  $102 \pm 2$  °C até estabilização do peso, sendo pesadas em seguida, para determinação do peso seco. A densidade básica ( $d$ ) foi obtida pela relação entre a massa seca da madeira e o volume saturado. As espécies que não tiveram  $d$  determinada em laboratório tiveram suas densidades substituídas pela média de todas as densidades do projeto a que pertenciam.

### 3.2.1 Distribuição diamétrica

Para analisar a distribuição diamétrica, as árvores com  $DAP \geq$  ao nível de inclusão (5 cm) foram classificadas e contabilizadas em classes de diâmetro. Os indivíduos amostrados foram distribuídos em classes de diâmetro (amplitude de 5 cm) para a construção do histograma de frequências absolutas. O coeficiente 'q' de De Liocourt descreveu a estrutura diamétrica, e foi calculado pela razão entre o número de indivíduos de uma determinada classe diamétrica pelo número de indivíduos da classe superior.

### 3.2.2. Obtenção do volume

A área de estudo está presente em uma região de reserva legal, levando em consideração este fator, não foi realizada a derrubada de árvores-amostra para realização de cubagem rigorosa e, conseqüentemente, para obtenção de equações volumétricas e fatores de forma das árvores. De acordo com a Fundação Centro Tecnológico de Minas Gerais - CETEC (1995), para árvores individuais de Floresta Estacional Semidecidual no estado de Minas Gerais, pode-se estimar o volume total com casca por meio da equação apresentada a seguir

$$V_t = 0,0000740 * DAP^{1,707341} * Ht^{1,16873}, R^2 = 97,3 \quad [1]$$

em que:

$V_t$  = volume total com casca, em  $m^3$ ;  $DAP$  = diâmetro a 1,30 do nível do solo, com casca, em cm e  $Ht$  = altura total, em m.



O volume total com casca obtidos pela equação 1, foi utilizado como referência para fins de análise.

### 3.2.3 Obtenção da biomassa

Para as estimativas de biomassa, considerou-se biomassa total ( $Bt$ ) a biomassa da parte aérea da árvore, incluindo fuste e copa.

A biomassa foi obtida para cada indivíduo, ao multiplicar a densidade da madeira da espécie ( $d$ ) pelo volume total com casca ( $Vt$ ) conforme a equação 2 :

$$Bt = d * Vt \quad [2]$$

em que:

$Bt$  = biomassa total ( $t$ );  $d$  = densidade da espécie ( $\text{g.cm}^{-3}$ ) e  $Vt$  = volume total com casca ( $\text{m}^3$ ).

### 3.3. Obtenção da biomassa por meio de RNA

Para estimativa de biomassa, por indivíduo, utilizou-se variáveis contínuas e categóricas. As variáveis contínuas utilizadas foram: diâmetro a 1,30 do nível do solo ( $DAP$ ), densidade básica da madeira ( $d$ ), altura total ( $Ht$ ), altura de fuste ( $Hf$ ), volume total ( $Vt$ ). As variáveis categóricas utilizadas foram: fitofisionomia ( $FT$ ), infestação de cipós ( $CP$ ), qualidade de copa ( $QC$ ) e coeficiente de De Liocourt ( $q$ ).

No treinamento das RNA para estimativa de biomassa total, foram testadas diferentes combinações de variáveis na camada de entrada, apresentadas na tabela 2.

Tabela 2 - Variáveis de entrada das redes neurais artificiais

Entrada 1	$DAP, d, Ht, Vt$
Entrada 2	$DAP, d, Hf, Vt$
Entrada 3	$DAP, d, Ht, Vt, FT$
Entrada 4	$DAP, d, Hf, Vt, FT$
Entrada 5	$DAP, d, Ht, Vt, CP$
Entrada 6	$DAP, d, Hf, Vt, CP$
Entrada 7	$DAP, d, Ht, Vt, QC$
Entrada 8	$DAP, d, Hf, Vt, QC$
Entrada 9	$DAP, d, Ht, Vt, q$
Entrada 10	$DAP, d, Hf, Vt, q$

Continua...

Tabela 2 – Cont.

Entrada 11	<i>DAP, d, Ht, Vt, FT, CP, QC, q</i>
Entrada 12	<i>DAP, d, Hf, Vt, FT, CP, QC, q</i>
Entrada 13	<i>DAP, d, Vt, Ht, CP, QC</i>
Entrada 14	<i>DAP, d, Vt, Hf, CP, QC</i>

Em que: Diâmetro a 1,30 do nível do solo (*DAP*), Densidade básica da madeira (*d*), Altura total (*Ht*), Altura de fuste (*Hf*), Volume total (*Vt*), fitofisionomia (*FT*), Infestação de cipós (*CP*), Qualidade de copa (*QC*) e Coeficiente De Liocourt (*q*).

As entradas 1 e 2 utilizaram apenas variáveis contínuas. A diferença entre elas foi a altura utilizada, a entrada 1 utilizou a altura total (*Ht*) e a entrada 2 altura de fuste (*Hf*), e as demais variáveis foram comuns a duas entradas. As variáveis contínuas e categóricas foram combinadas para gerar os demais grupos de entradas das redes (entradas de 3 a 14) e também consideraram a diferença na estimativa de biomassa total ao utilizar *Ht* ou *Hf*. Foi importante considerar a diferença entre as entradas em todas as situações, pois em geral, a mensuração da altura de fuste gera estimativas mais precisas, já que os métodos de mensuração em florestas nativas possuem limitações para visualização da altura total das árvores de grande porte.

Para a entrada das RNA, as variáveis categóricas devem ser codificadas quantitativamente. Assim, as variáveis foram transformadas em vetores numéricos com dimensão igual a quantidade de classes de cada variável. Para a variável *FT*, os elementos do vetor assumiram valores de 0 ou 1, onde zero indica ausência de atributo e um, sua presença. Por exemplo, para uma árvore classificada na categoria ‘Submontana’ seria representada pelo vetor (1,0), já para uma árvore classificada na categoria ‘Montana’ o vetor seria (0,1).

Para a variável *QC*, os elementos do vetor assumiram os valores 1, 2 ou 3 em que 1 representa a classe ‘Inferior’, 2 a classe ‘Regular’ e 3 a classe ‘Boa’. De forma análoga, para a variável *CP*, os elementos do vetor assumiram os valores 1, 2, 3, ou 4 em que 1 representa ‘Cipós no tronco e na copa’, 2 ‘Cipós somente na copa’, 3 ‘Cipós somente no tronco’ e 4 ‘Nenhum cipó’. A representação dessa forma buscou dar maior contribuição nas estimativas de biomassa para as árvores das melhores classes de *QC* e *CP* (maiores valores dos elementos dos vetores de entrada), com isso, ocasionando em resultados mais próximos da realidade biológica.

Na etapa de pré-processamento realizou-se a normalização linear das variáveis de entrada da rede, condensando os valores no intervalo de 0 a 1. Os valores normalizados foram obtidos por meio da equação 3 :

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad [3]$$

em que:

$x'$  = Valor normalizado;  $x$  = Valor original;  $x_{max}$  = Valor máximo da variável e  $x_{min}$  = Valor mínimo da variável.

A RNA utilizada foi a Perceptron de múltiplas camadas (MLP). O método de aprendizagem foi o supervisionado e as redes utilizadas do tipo anteroalimentadas (*feedforward*). A função de ativação da camada intermediária e da saída foi a logística.

As RNA foram treinadas por meio do algoritmo de retropropagação do erro (*backpropagation*); a taxa de aprendizagem utilizada foi de 0,3 e utilizou-se o termo *momentum*. O treinamento foi finalizado ao atingir o número máximo de 1.000 iterações.

Foi utilizado o método de validação cruzada *k-fold cross-validation* que dividiu o conjunto total da amostra em  $k$  partições com  $k = 10$ . Dessa forma, 90% da amostra foi utilizada para compor o subconjunto de treinamento e 10% constituiu o subconjunto de teste.

Primeiramente, foi definido o número de neurônios da camada oculta ( $N$ ), isto é, a topologia de cada grupo de entrada. Para cada  $n$  candidato foram treinadas 10 RNA, com  $N$  variando de 1 à 20, totalizando 200 RNA para cada situação. O desempenho de cada topologia candidata foi avaliado por meio da média do erro médio quadrático ( $EMQ$ ) para cada valor de  $N$ . A topologia selecionada foi determinada a partir do menor  $EMQ_{medio}$ , associado ao desvio padrão dos erros.

O  $EMQ$  é a soma das diferenças entre o valor estimado e o valor real dos dados, ponderados pelo número de termos, conforme a equação 4.

$$EMQ = \frac{1}{n} \sum_{i=0}^n (y_{est} - y_{obs})^2 \quad [4]$$

em que:

$EMQ$  = Erro médio quadrático;  $n$  = número de observações;  $y_{est}$  = biomassa estimada pela RNA e  $y_{obs}$  = biomassa observada.

Após a definição da topologia candidata, realizou-se uma segunda etapa, contendo um novo procedimento de validação cruzada *k-fold* para validação dos dados e estimativa de biomassa. De forma análoga a definição da topologia, foram treinadas 10 RNA para cada grupo de entrada (com a topologia definida) e selecionou-se a rede que apresentou o menor  $EMQ$ .

O processamento das informações foi realizado por meio do *software* R Core Team (2015), versão 3.2.0 com apoio da plataforma RStudio versão 0.98.983. Os pacotes utilizados para processar as RNA foram: RSNNS (2012), cvTools (2012), devtools (2015) e Metrics (2012). As funções utilizadas e as linhas de comando estão apresentadas no apêndice A.

### 3.3.1. Avaliação da qualidade das RNA

As RNA foram avaliadas a partir da análise do Erro Médio Quadrático (*EMQ*), Coeficientes de correlação, Variância, Bias, e a Análise gráfica dos resíduos percentuais (equação 5).

$$E\% = \frac{(y_{est} - y_{obs})}{y_{obs}} * 100 \quad [5]$$

em que:

E% = Resíduo percentual;  $y_{est}$  = biomassa estimada, em toneladas ( $t$ ) e  $y_{obs}$  = biomassa observada, em toneladas ( $t$ ).

Na fase de validação da RNA, a análise foi realizada por parcelas, que é a unidade de amostra da área. Dessa forma, a estimativa de biomassa total é obtida inicialmente por indivíduo, e os resultados para análise da validação das RNA foram provenientes do somatório das biomassas desses indivíduos, reunidos em parcelas.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Análise Exploratória dos Dados

Foram registrados 3.621 indivíduos arbóreos com *DAP* igual ou superior a 5 cm. A área basal encontrada foi de 21,37 m<sup>2</sup>.ha<sup>-1</sup>. O volume encontrado para os 3.621 indivíduos, de acordo com a equação do CETEC (1995) foi: Volume total com casca = 182,55 m<sup>3</sup>.ha<sup>-1</sup>. E a biomassa total = 110,81 t.ha<sup>-1</sup>.

Considerando o total de indivíduos, 82,82% das árvores foram classificadas de acordo com a qualidade de copa em ‘boa’, 13,04% ‘regular’ e 4,14% ‘inferior’. Já para a infestação de cipós, as classes ‘Nenhum cipós’, ‘Cipós somente no tronco’, ‘Cipós somente na copa’ e ‘Cipós no tronco e na copa’ apresentaram 82,21%; 0,75%; 6,27% e 10,77 %, respectivamente. Em relação a fitofisionomia, 36,23% dos indivíduos foram classificados na Floresta Estacional Semidecidual Submontana (293,16 ha), representando 2.624 ind./ha e

63,77% na Floresta Estacional Semidecidual Montana (204,6 ha), representando 4.618 ind./ha.

A descrição das variáveis contínuas utilizadas no treinamento das RNA, em nível de árvore, estão presentes na tabela 3.

Tabela 3 - Descrição das variáveis contínuas utilizadas como entradas das RNA, em nível de árvore. Em que *DAP* - Diâmetro à 1,30 m do solo, *Ht* - Altura Total, *Hf* - Altura de fuste, *Vt* - Volume total e a respectiva saída *Bt* - Biomassa total

	<i>DAP</i> (cm)	<i>Ht</i> (m)	<i>Hf</i> (m)	<i>Vt</i> (m <sup>3</sup> )	<i>Bt</i> (t)
Máximo	98,51	35,0	23,0	11,9503	5,8556
Médio	11,07	10,1	5,5	0,1361	0,0826
Mínimo	5,00	1,5	0,5	0,0035	0,0021
Desvio padrão	7,11	2,7	4,3	0,3941	0,2299

Pode-se observar uma alta variação nos *DAP* (de 5,00 a 98,51cm) e nas *Ht* e *Hf* (1,5 a 35,0 m e 0,5 a 23,0 m respectivamente), o que é esperado devido ao comportamento natural da floresta, reflexo da grande diversidade florística, fisionômica e fenológica em florestas inequidâneas.

As relações entre as variáveis contínuas de entrada das RNA são apresentadas na Figura 5. Os gráficos mostram o comportamento das variáveis *Ht*, *Hf*, biomassa e volume em função da variável *DAP*, assim como o comportamento da variável Biomassa em função de *Ht* e *Hf*.

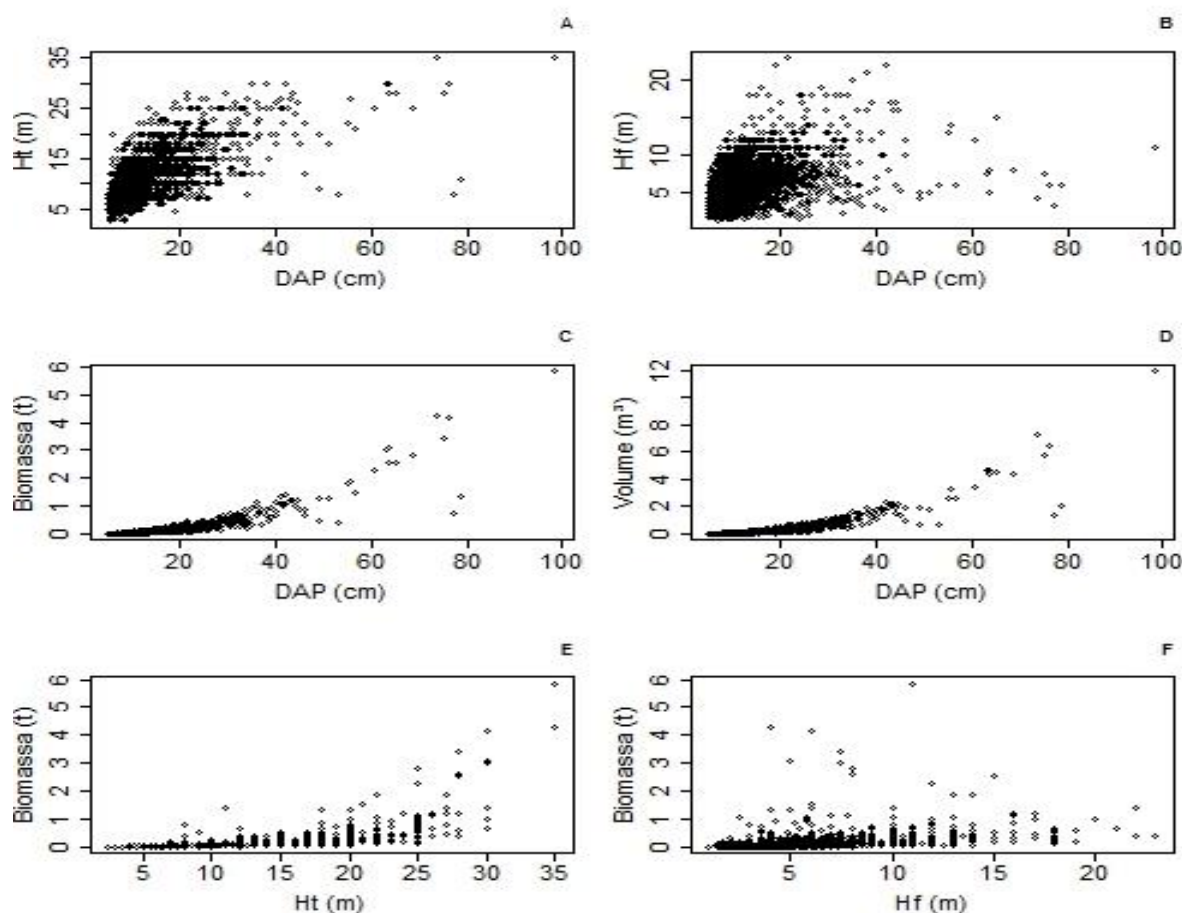


Figura 5 - Relação entre variáveis Diâmetro à 1,30 do nível do solo (*DAP*), Altura total (*Ht*), Altura de fuste (*Hf*), Biomassa e Volume.

Na Figura 5 percebe-se que a distribuição das alturas (*Ht* e *Hf*) e dos volumes em função do *DAP*, tem maior concentração na faixa dos menores diâmetros. Foi observada grande variação das alturas para uma mesmo valor de diâmetro (Figura 5 - A e B). Isso demonstra que nesse caso não houve uma relação direta entre as alturas em função do diâmetro das árvores. Em florestas nativas é comum que árvores com mesmos diâmetros apresentarem diferentes alturas, assim como, o inverso.

A biomassa e volume apresentam comportamento semelhante em função do diâmetro, conforme gráficos C e D da Figura 5, onde pode-se perceber que a concentração de biomassa e volume está nos menores diâmetros, devido à distribuição diamétrica da população, com maior quantidade de indivíduos menores, como já era esperado para florestas inequiduais com um número maior de indivíduos com menores diâmetros à 1,30m do nível do solo. Nota-se a partir do gráfico F da Figura 5 que a biomassa concentrou-se nas menores alturas de fuste, visto que 57,47% das alturas de fuste encontram-se abaixo da média das mesmas.

A concentração de biomassa em relação a altura total foi melhor distribuída devido a uma maior amplitude das alturas totais (Figura 5 - E). Enquanto a amplitude da altura de fuste foi de 1 a 23m, a altura total apresentou amplitude de 2,5 a 35m.

A estrutura diamétrica da floresta seguiu o padrão das florestas inequianéas, ou seja, apresentou distribuição exponencial negativa na forma de J invertido como pode ser observado da Figura 6. Esse fato é esperado devido a característica das florestas naturais de possuírem a maior concentração dos indivíduos arbóreos nas menores classes de diâmetros que, individualmente, representam uma pequena parte da biomassa total da população (MEYER, 1952; BARBOUR et al., 1987).

Neste mesmo sentido, Machado et al. (2004) afirmam que a maioria dos inventários de comunidades arbóreo-arbustivas em florestas naturais apresenta uma distribuição diamétrica seguindo o modelo J invertido, com alta concentração de indivíduos nas classes menores e redução acentuada no sentido das classes maiores. Esse comportamento de distribuição diamétrica é observado em estudos que consideram os indivíduos com *DAP* igual ou superior a 5 cm para inclusão no inventário florestal.




Figura 6 - Distribuição do número de indivíduos por hectare por classe de diâmetro em cm, e o coeficiente de De Liocourt. Em que CCD é o centro da classe diamétrica e 'q' é coeficiente de De Liocourt para a referente CCD.

Os 3621 indivíduos com  $DAP \geq 5$  cm, inseridos na amostragem, foram distribuídos em dezenove classes de diâmetro com 5 cm de amplitude. E as classes com CCD 82,5; 87,5 e 92,5 não apresentaram nenhum indivíduo, evidenciando que a maioria dos indivíduos são árvores de pequeno porte. A primeira classe de  $DAP$  (5 - 9,9 cm) apresentou 53,33% dos indivíduos. A árvore de maior  $DAP$  (98,51 cm) inserida na amostragem foi a única representante da última classe de diâmetro.

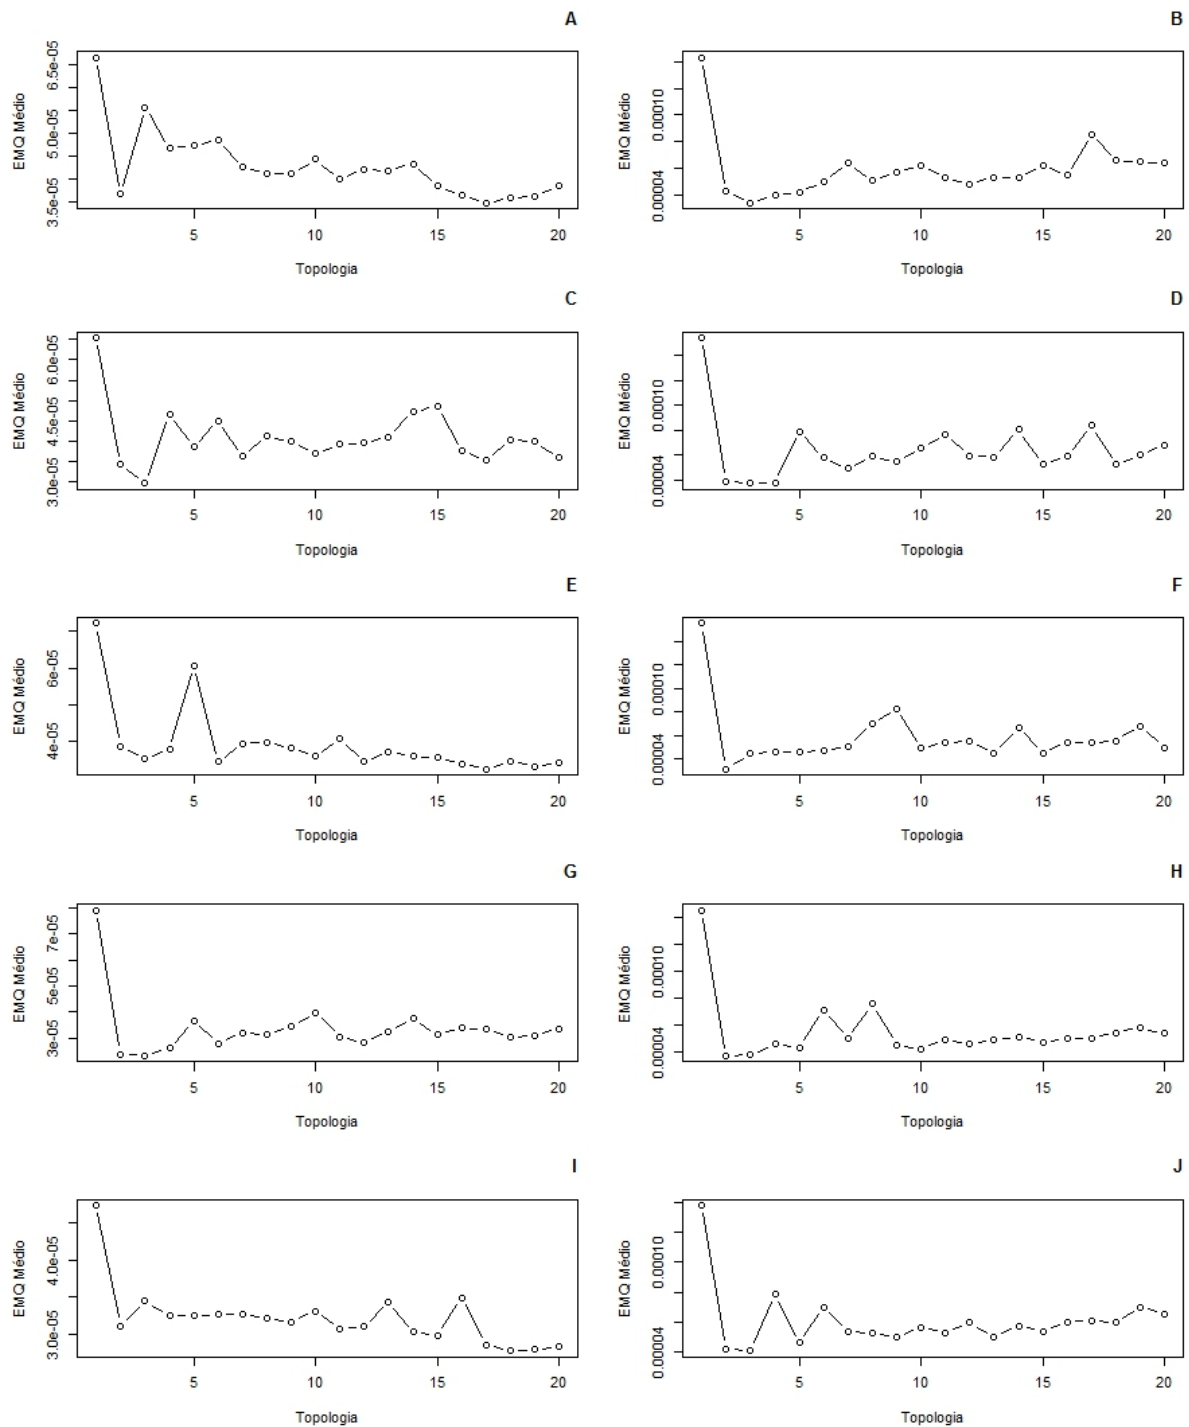
O coeficiente de De Liocourt ( $q$ ) variou de 2,83 a 0,25. Isso demonstra que a floresta está desbalanceada, em processo de sucessão. As classes de diâmetros superiores apresentaram maior instabilidade do ‘ $q$ ’, por apresentar déficit de árvores nas mesmas. Tratando-se de área de preservação, onde não há a retirada de produtos da floresta, estes resultados podem estar associados ao processo regeneração natural e estágio sucessional.

#### 4.2. Definição da topologia

O resultado da validação cruzada para a primeira etapa do estudo foi a definição do número de neurônios das camadas ocultas. Para cada grupo de entrada, foram treinadas 200 RNA a fim de encontrar a topologia mais adequada para cada situação, e as topologias definidas foram as que apresentaram o menor  $EMQ_{\text{médio}}$  associado ao desvio padrão.

A Figura 7 mostra a variação do  $EMQ_{\text{médio}}$  em função do número de neurônios da camada oculta de cada grupo de entrada para estimativas de biomassa total.





Continua...

Figura 7 - Definição da topologia para estimativas de biomassa total. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

Fig. 7 - Cont.

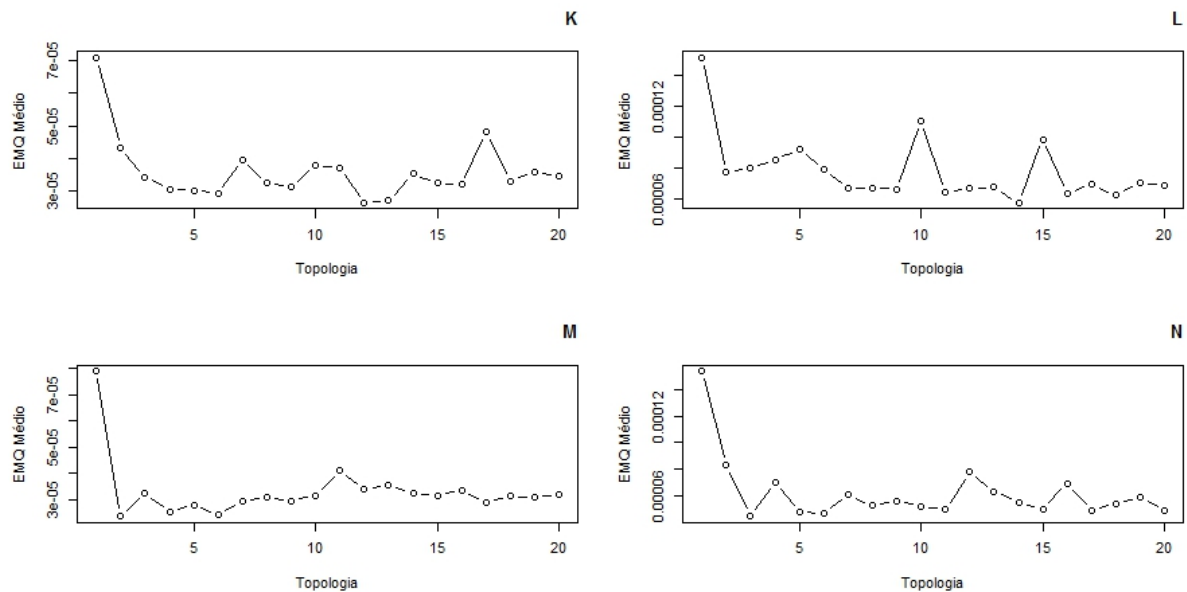


Figura 7 - Definição da topologia para estimativas de biomassa total. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

Pode-se perceber pela Figura 7 que em todos os casos, um neurônio não generaliza os dados com precisão, tendo os maiores  $EMQ_{médio}$ . De acordo com Silva et al. (2010), uma rede com número de neurônios muito superior ao necessário para resolução do problema pode perder a capacidade de generalizar, não respondendo corretamente aos padrões nunca vistos, que serão inseridos na etapa de validação. O número de neurônios com  $EMQ_{médio}$  satisfatório foi encontrado com menos de 20 neurônios. Como a partir de 18 neurônios houve a tendência de estabilização, não foi necessário testar maiores amplitudes. No caso do grupo de entrada com variáveis contínuas e adição da variável categórica ‘fitofisionomia’ e altura de fuste, com 20 neurônios o  $EMQ_{médio}$  não seguiu a tendência de diminuir ou estabilizar, porém com 4 neurônios o erro foi menor e definiu-se o número de neurônios da camada oculta. De 2 a 17 neurônios, há uma generalização mais adequada, no entanto, não foi verificado uma tendência entre o aumento do número de neurônios e a diminuição do  $EMQ_{médio}$ , cada situação teve um comportamento, como pode ser observado na tabela 4.

Tabela 4 - Características das RNA para estimar biomassa total de uma Floresta Estacional Semidecidual em Minas Gerais. Em que *DAP* = diâmetro a 1,30 m do nível do solo; *d* = densidade básica da madeira; *Ht* = altura total; *Hf* = altura de fuste; *Vt* = volume total; *FT* = fitofisionomia; *CP* = infestação de cipós; *QC* = qualidade de copa; *q* = coeficiente de De Liocourt; *Bt* = biomassa total;  $EMQ_{\text{médio}}$  = erro médio quadrático médio; *Sd* = Desvio padrão; número de variáveis da camada de entrada (camada E), número de neurônios da camada intermediária (camada I) e número de variáveis da camada de saída (camada S)

RNA	Variáveis de entrada		Saída	Camadas			$EMQ \pm Sd$
	Contínuas	Catégoricas		E	I	S	
A	<i>DAP, d, Ht, Vt</i>	-	<i>Bt</i>	4	17	1	$3,4752.10^{-05} \pm 2,9737.10^{-05}$
B	<i>DAP, d, Hf, Vt</i>	-	<i>Bt</i>	4	3	1	$3,3792.10^{-05} \pm 3,0444.10^{-05}$
C	<i>DAP, d, Ht, Vt</i>	<i>FT</i>	<i>Bt</i>	5	3	1	$2,8967.10^{-05} \pm 4,0009.10^{-05}$
D	<i>DAP, d, Hf, Vt</i>	<i>FT</i>	<i>Bt</i>	5	4	1	$3,7811.10^{-05} \pm 3,1491.10^{-05}$
E	<i>DAP, d, Ht, Vt</i>	<i>CP</i>	<i>Bt</i>	5	17	1	$3,2576.10^{-05} \pm 3,0560.10^{-05}$
F	<i>DAP, d, Hf, Vt</i>	<i>CP</i>	<i>Bt</i>	5	2	1	$3,1838.10^{-05} \pm 3,7032.10^{-05}$
G	<i>DAP, d, Ht, Vt</i>	<i>QC</i>	<i>Bt</i>	5	3	1	$2,3076.10^{-05} \pm 1,9795.10^{-05}$
H	<i>DAP, d, Hf, Vt</i>	<i>QC</i>	<i>Bt</i>	5	2	1	$3,6750.10^{-05} \pm 3,4962.10^{-05}$
I	<i>DAP, d, Ht, Vt</i>	<i>q</i>	<i>Bt</i>	5	18	1	$2,7752.10^{-05} \pm 2,1085.10^{-05}$
J	<i>DAP, d, Hf, Vt</i>	<i>q</i>	<i>Bt</i>	5	3	1	$4,0815.10^{-05} \pm 3,1506.10^{-05}$
K	<i>DAP, d, Ht, Vt</i>	<i>FT, CP, QC, q</i>	<i>Bt</i>	8	12	1	$2,6550.10^{-05} \pm 1,8730.10^{-05}$
L	<i>DAP, d, Hf, Vt</i>	<i>FT, CP, QC, q</i>	<i>Bt</i>	8	14	1	$5,7284.10^{-05} \pm 3,4219.10^{-05}$
M	<i>DAP, d, Ht, Vt</i>	<i>CP, QC</i>	<i>Bt</i>	6	2	1	$2,3638.10^{-05} \pm 2,3018.10^{-05}$
N	<i>DAP, d, Hf, Vt</i>	<i>CP, QC</i>	<i>Bt</i>	6	3	1	$4,4558.10^{-05} \pm 3,1299.10^{-05}$

O  $EMQ_{\text{médio}}$  variou de  $2,3076.10^{-05} \pm 1,9795.10^{-05}$  a  $5,7284.10^{-05} \pm 3,4219.10^{-05}$ . Os valores dos  $EMQ_{\text{médio}}$  se mostraram baixos, evidenciando elevada precisão para o uso das arquiteturas definidas.

Nas três situações em que o número de neurônios da camada oculta foi maior (N = 17 (RNA A e E) e N = 18 (RNA I)), essas topologias foram definidas associadas à variável *Ht* na camada de entrada. Para esses casos, quando associados à variável *Hf*, o número de neurônios da camada oculta foi bem menor (3 e 2) e os  $EMQ_{\text{médio}}$  obtiveram melhores resultados, mostrando a não necessidade de um número elevado de neurônios na camada oculta. Porém nas redes que utilizaram todas as variáveis catégoricas, aumentando assim a quantidade de variáveis de entrada, houve a necessidade de mais neurônios na camada oculta (RNA K e L), mostrando que em cada situação tem sua necessidade específica e deve-se buscar o número mais adequado de neurônios para o processamento da RNA.

#### 4.3. Estimativa de biomassa por meio de RNA

As RNA que apresentaram o melhor desempenho, em cada situação, após a nova *cross-validation* e suas respectivas estatísticas de ajuste são apresentadas na tabela 5.

Tabela 5 - Arquiteturas das RNA selecionadas para estimativa de biomassa total de uma Floresta Estacional Semidecidual em Minas Gerais e suas respectivas estatísticas. Em que *DAP* = diâmetro a 1,30 m do nível do solo; *d* = densidade básica da madeira; *Ht* = altura total; *Hf* = altura de fuste; *Vt* = volume total; *FT* = fitofisionomia; *CP* = infestação de cipós; *QC* = qualidade de copa; *q* = Coeficiente de De Liocourt; *Bt* = biomassa total; *EMQ* = erro médio quadrático e  $r_{y\hat{y}}$  = coeficiente de correlação


RNA	Arquitetura	Variáveis de entrada	Saída	<i>EMQ</i>	$r_{y\hat{y}}$	<i>Bias</i>	Variância
A	4-17-1	<i>DAP, d, Ht, Vt</i>	<i>Bt</i>	$1,5509.10^{-05}$	0,9932	0,181	0,033
B	4-3-1	<i>DAP, d, Hf, Vt</i>	<i>Bt</i>	$1,5868.10^{-05}$	0,9965	0,257	0,066
C	5-3-1	<i>DAP, d, Ht, Vt, FT</i>	<i>Bt</i>	$1,0217.10^{-05}$	0,9983	0,280	0,078
D	5-4-1	<i>DAP, d, Hf, Vt, FT</i>	<i>Bt</i>	$1,5772.10^{-05}$	0,9862	0,119	0,014
E	5-17-1	<i>DAP, d, Ht, Vt, CP</i>	<i>Bt</i>	$1,4857.10^{-05}$	0,9986	0,391	0,153
F	5-2-1	<i>DAP, d, Hf, Vt, CP</i>	<i>Bt</i>	$1,2292.10^{-05}$	0,9926	0,159	0,025
G	5-3-1	<i>DAP, d, Ht, Vt, QC</i>	<i>Bt</i>	$1,0672.10^{-05}$	0,9963	0,213	0,045
H	5-2-1	<i>DAP, d, Hf, Vt, QC</i>	<i>Bt</i>	$1,6384.10^{-05}$	0,9722	0,096	0,009
I	5-18-1	<i>DAP, d, Ht, Vt, q</i>	<i>Bt</i>	$1,1397.10^{-05}$	0,9898	0,127	0,016
J	5-3-1	<i>DAP, d, Hf, Vt, q</i>	<i>Bt</i>	$1,7831.10^{-05}$	0,9896	0,135	0,018
K	8-12-1	<i>DAP, d, Ht, Vt, FT, CP, QC, q</i>	<i>Bt</i>	$1,1699.10^{-05}$	0,9956	0,207	0,043
L	8-14-1	<i>DAP, d, Hf, Vt, FT, CP, QC, q</i>	<i>Bt</i>	$1,8486.10^{-05}$	0,9880	0,140	0,019
M	6-2-1	<i>DAP, d, Ht, Vt, CP, QC</i>	<i>Bt</i>	$7,4646.10^{-06}$	0,9912	0,110	0,012
N	6-3-1	<i>DAP, d, Hf, Vt, CP, QC</i>	<i>Bt</i>	$1,4665.10^{-05}$	0,9722	0,088	0,007

É possível observar que as redes diferiram pouco entre si, e todas as redes selecionadas no treinamento para projeção da biomassa total, apresentaram correlações iguais ou maiores que 0,9722 indicando alta precisão entre as estimativas e os valores reais das variáveis analisadas. Almeida et al. (2009) encontraram o coeficiente de correlação entre os dados reais e estimados de volume de biomassa de 0,81, valor este, que segundo os autores possui uma confiabilidade aceitável. Foody et al. (2001) consideraram como correlação alta entre as estimativas de biomassa e os dados mensurados em campo um valor igual a 0,8033, sendo que testando três diferentes tipos de rede, encontrou correlação variando de 0,4622 a 0,8033. Os valores de coeficientes de correlação encontrados neste trabalho, são superiores aos apresentados nos trabalhos de Almeida et al. (2009) e Foody et al. (2001), e podem ser considerados de alta confiabilidade. A superioridade dos valores dos coeficientes de correlação encontrados neste trabalho pode ser explicada devido à alta correlação entre as variáveis dendrométricas utilizadas como entrada das RNA. Além das variáveis comumente mensuradas nos inventários florestais (*DAP* e *Ht/Hf*), utilizou-se a densidade básica da madeira que é importante e altamente correlacionada com a variável de interesse, a biomassa, e as variáveis categóricas que acrescentaram na entrada das redes informações importantes à respeito da área em estudo.

Há menor correlação em dados que integram diferentes escalas e fontes (como imagens de satélites e inventário florestal) para obtenção de dados de biomassa em floresta natural do que dados provenientes de uma fonte única (inventário florestal por exemplo), coletados em campo. De acordo com Ponzoni (2001), o aspecto da cobertura vegetal gerada por uma imagem de satélite inclui também a interferência de diversos parâmetros e fatores como propriedades do dossel da vegetação, efeitos da atmosfera, características dos solos e diversidade florística. Essas interferências nas imagens podem explicar a não ocorrência de altas correlações entre as variáveis oriundas de sensoriamento remoto e variáveis dendrométricas.

De modo geral, as redes MLP apresentaram arquitetura simples, poucos desvios e pouca tendenciosidade, expressos pelos valores baixos de *Bias*, *EMQ* e amplitude do erro, evidenciando melhor capacidade de aprendizado. Ao avaliar as duas diferentes alturas, os resultados mais satisfatórios foram encontrados, na maioria dos casos, em RNA que utilizaram a *Ht* como variável de entrada. Apenas no caso da adição da variável categórica *CP* às variáveis contínuas na camada de entrada da RNA, a *Hf* teve o melhor desempenho.

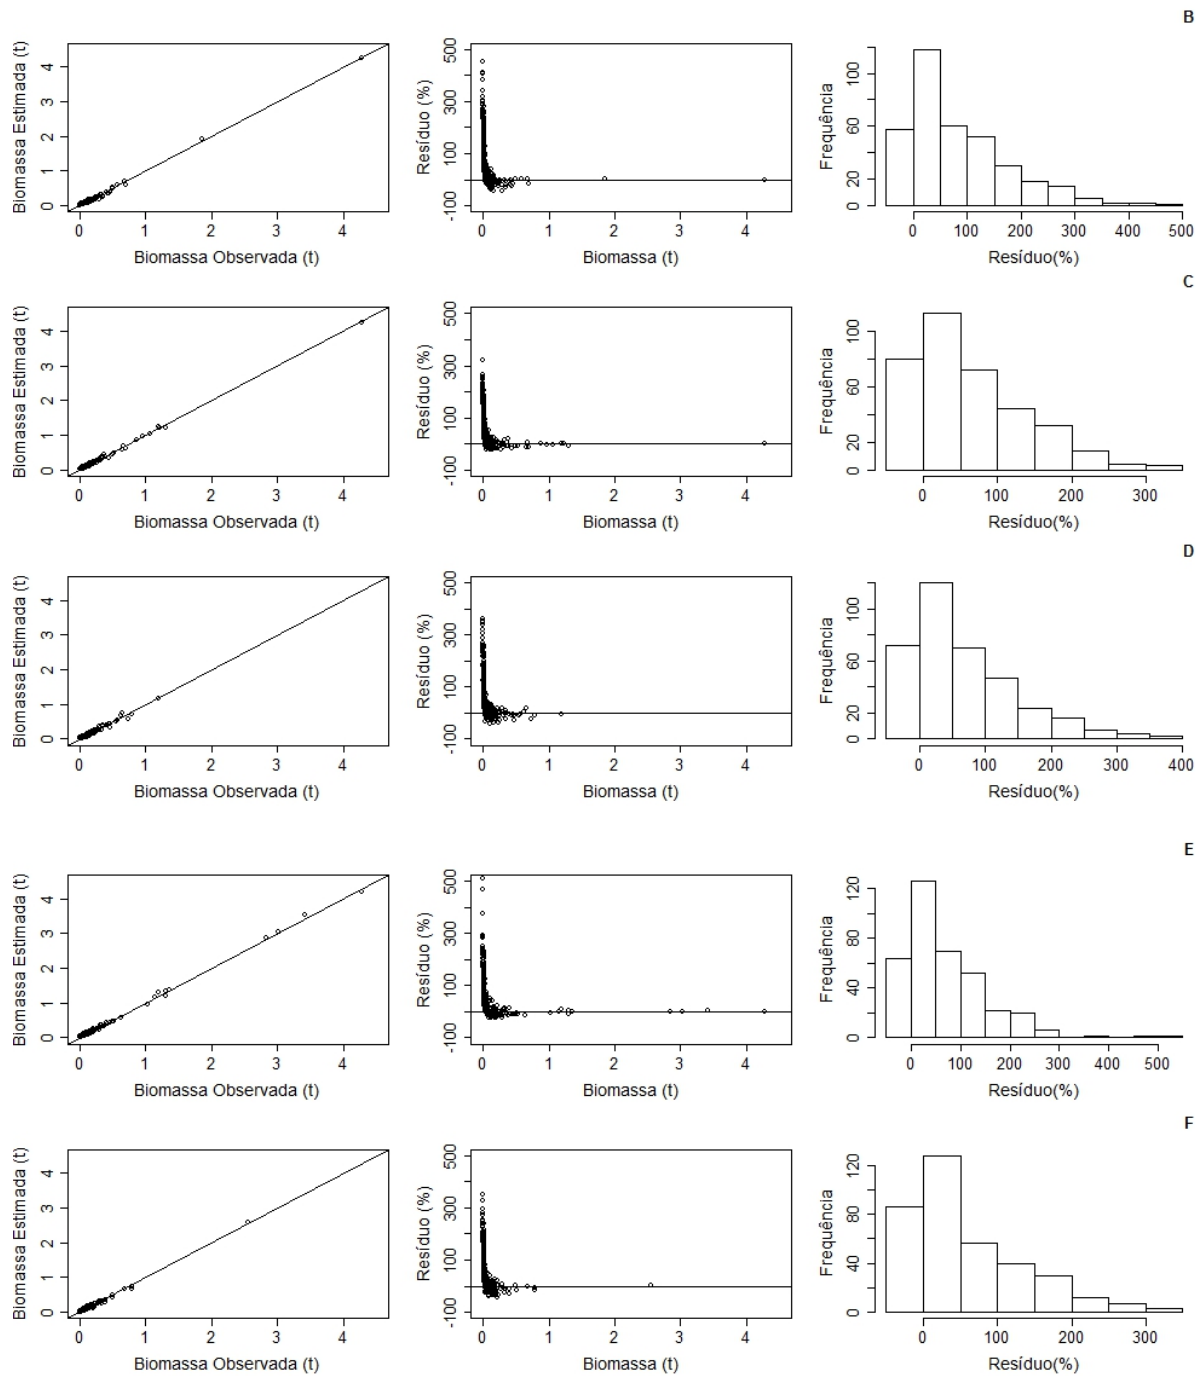
A Figura 8 apresenta a análise gráfica dos resíduos das RNA por meio da relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e o histograma de frequência de resíduos.



Continua...

Figura 8: Relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e histograma de frequência de resíduos. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

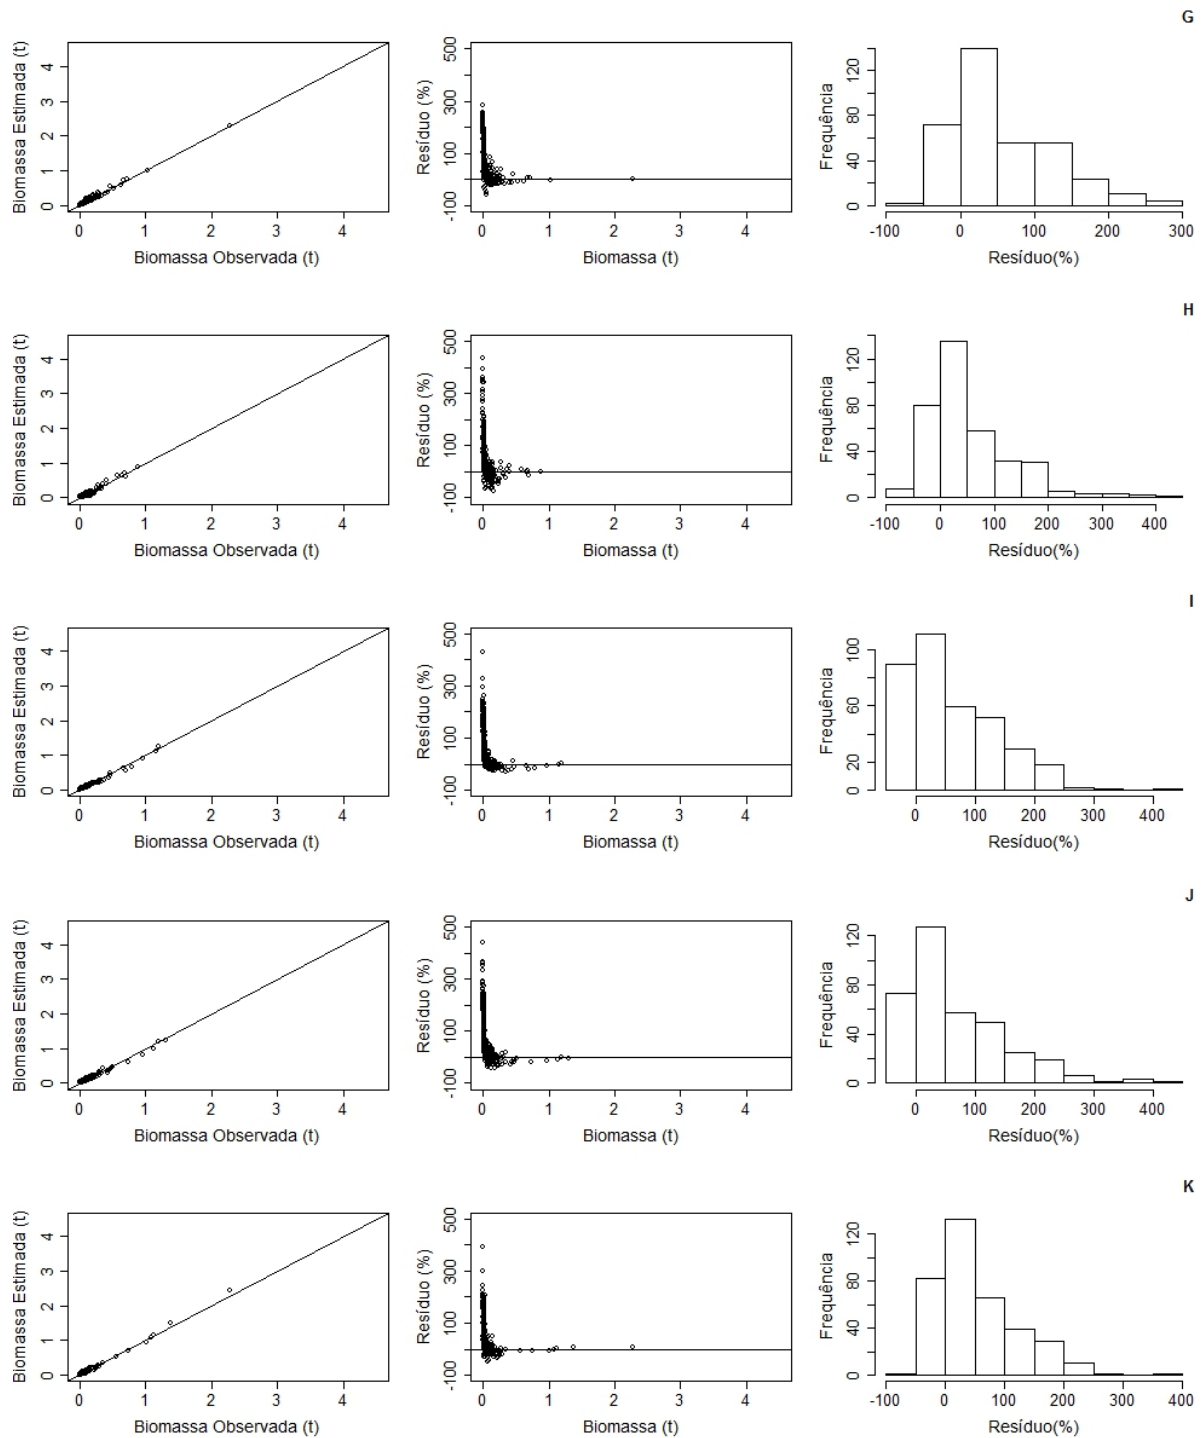
Fig. 8 - Cont.



Continua...

Figura 8: Relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e histograma de frequência de resíduos. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

Fig. 8 - Cont.



Continua...

Figura 8: Relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e histograma de frequência de resíduos. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

Fig. 8 - Cont.

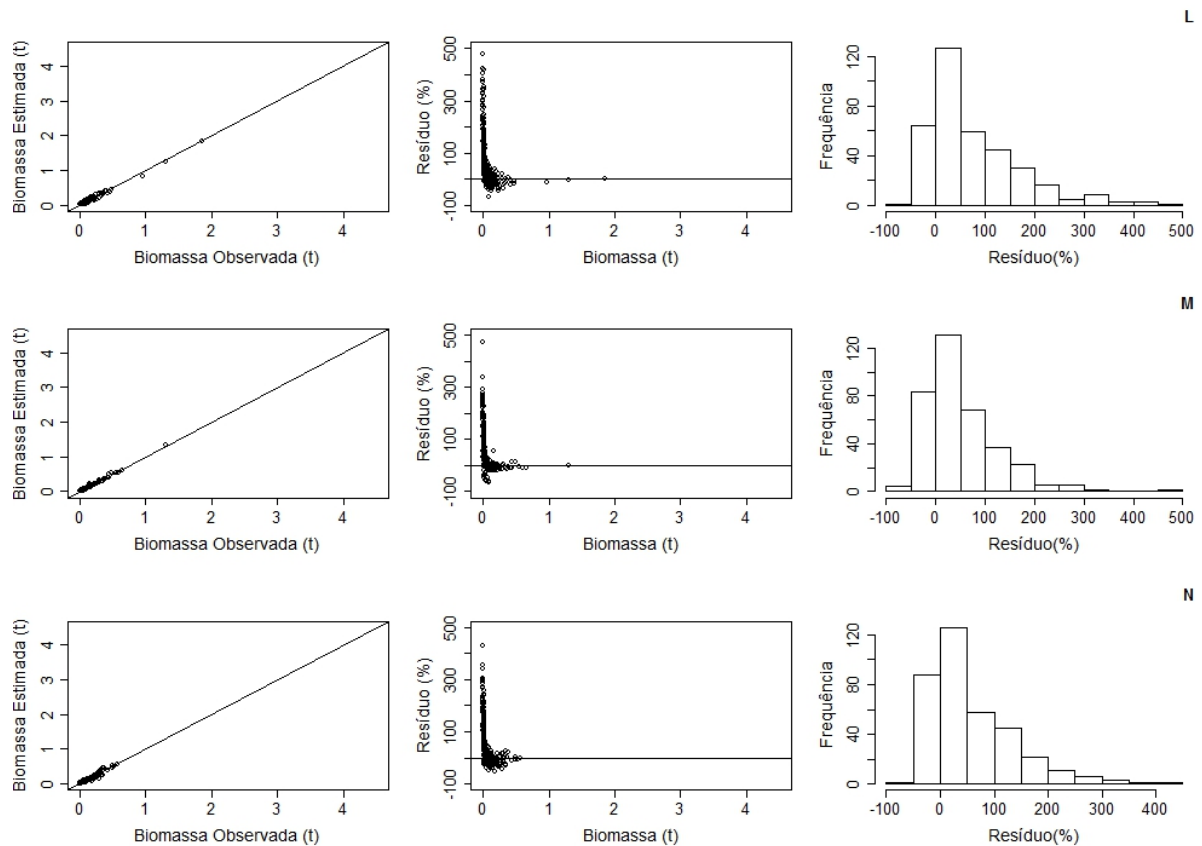


Figura 8: Relação entre valores observados e estimados de biomassa total, dispersão dos resíduos em função da biomassa observada e histograma de frequência de resíduos. A) Variáveis contínuas com altura total. B) Variáveis contínuas com altura de fuste. C) Fitofisionomia com altura total. D) Fitofisionomia com altura de fuste. E) Infestação de cipós com altura total. F) Infestação de cipós com altura de fuste. G) Qualidade de copa com altura total. H) Qualidade de copa com altura de fuste. I) Coeficiente de De Liocourt com altura total. J) Coeficiente de De Liocourt com altura de fuste. K) Variáveis categóricas com altura de total. L) Variáveis categóricas com altura de fuste. M) Infestação de cipó e qualidade de copa com altura total. N) Infestação de cipó e qualidade de copa com altura de fuste.

Os resultados dos ajustes das RNA selecionadas indicam que a estimativa foi satisfatória, no entanto, ao analisar a Figura 8, que mostra os gráficos de resíduos percentuais, é possível perceber que as estimativas geradas apresentaram uma tendência expressiva de superestimação para as árvores de menores diâmetros (com biomassa observada inferior). Essa tendência na maioria das vezes foi de superestimação, no entanto, também houve subestimação das estimativas para as árvores de menores diâmetros, porém, em menor quantidade. Os resultados mostraram uma certa dificuldade para estimar a biomassa com precisão nestas situações. Isso pode ocorrer por causa dos valores baixos de biomassa observados em árvores de menores diâmetros, fazendo com que o desvio da estimativa, ainda



que pequeno, resulte em um valor alto no cálculo do resíduo. A dificuldade de se obter estimativas precisas para árvores de menores diâmetros também foi observada por Binoti et al. (2014), apesar de encontrar estimativas de volumes estatisticamente semelhantes aos volumes observados.

Pode-se perceber que a dispersão dos dados de biomassa estimada em função da observada se encontra próxima à reta imaginária, indicando que as estimativas se apresentam próximas dos respectivos valores observados.

É importante ressaltar que os pontos que extrapolaram a tendência geral de cada biomassa estimada não foram eliminados, a fim de verificar a capacidade das redes neurais em lidar com possíveis outliers.

De acordo com os valores de ajuste das RNA já apresentados na Tabela 5 e as estimativas de biomassa utilizando apenas variáveis contínuas *DAP*, *d*, *Vt*, *Ht* ou *DAP*, *d*, *Vt*, *Hf*, nas camadas de entrada (Figura 8 - A e B), optou-se pela rede que utilizou *Ht* como variável de entrada (rede A). Nota-se que para essa RNA, os valores de *EMQ*, *Bias* e Variância são menores, justificando a escolha desta rede.

Observa-se para as RNA que utilizaram além das variáveis contínuas, a variável categórica *FT* na camada de entrada (Figura 8 - C e D), que a RNA C apresentou menor *EMQ* e maior  $r_{Y\hat{Y}}$  em relação a RNA D que teve *Hf* como variável de entrada, confirmando sua superioridade. Como os indivíduos deste trabalho se encontram em áreas com tipologias florestais distintas, a avaliação da influência da variável categórica *FT* foi importante, pois segundo CHAVE et al. (2005), as principais variáveis preditoras utilizadas em estudos de biomassa, em ordem de importância são: diâmetro do tronco, densidade da madeira, altura total e tipo florestal.

Em relação as RNA que utilizaram além das variáveis contínuas a variável categórica *CP* (Figura 8 - E e F), pode-se perceber que a RNA que utilizou a *Hf* (RNA F) apresentou menores valores de *EMQ*, *Bias* e Variância, portanto, foi definida como a mais apropriada. A presença de cipós, lenhosos ou não lenhosos, em um grau de infestação elevada, competem com as árvores, interferem na simetria de crescimento e taxas de mortalidade das mesmas, podem provocar deformações no fuste, além de se tornarem prejudicial à regeneração natural de várias espécies florestais (ENGEL et al., 1998). Neste estudo 82,21% dos indivíduos analisados não continham nenhum cipó, dos indivíduos que apresentaram cipós, 0,75% continha cipós somente no tronco; 6,27% continha cipós somente na copa e 10,77% continha cipós no tronco e na copa. A presença de cipós não diminuiu a relação de biomassa quantificada nessa área.

A RNA H teve valores de *Bias* e Variância menores que a RNA G. No entanto, a RNA G foi mais precisa para estimativa da biomassa com variáveis contínuas e a variável categórica *QC*, pois o valor do  $r_{Y\hat{Y}}$  foi de 0,9963 enquanto o da RNA H foi 0,9722, e seu valor de *EMQ* menor. Além dos ajustes, pode-se perceber menores valores de resíduos da RNA G comparados com a RNA H (Figura 8 - G e H).

Uma copa mal formada pode afetar o crescimento de uma árvore devido a deslocação da energia projetada para nova produção de ramos e substituição das folhas (FREITAS e BERTI FILHO, 1994). Neste estudo, 82,82% das árvores continha copas inteiras e bem distribuídas, dessa forma a variável qualidade de copa, não diminuiu a relação de biomassa total quantificada nessa área.

Para as redes que além das variáveis contínuas consideram a variável categórica *q* na camada de entrada, observa-se pela Tabela 5 que a RNA I, obteve menores valores de *EMQ*, *Bias* e Variância. Dessa forma, o conjunto de ajustes comprovam a superioridade no treinamento da RNA I para estimativa da biomassa, optando-se pela mesma para avaliar a influência da variável categórica *q*.

As RNA K e L consideraram além das variáveis contínuas, todas as variáveis categóricas, sendo elas, *FT*, *CP*, *QC* e *q* na camada de entrada, e foram diferenciadas pela variável contínua altura (RNA K - *Ht* e RNA L - *Hf*). Pelos resultados da Tabela 5, a superioridade da RNA K em relação a RNA L é evidente, devido ao menor *EMQ* e maior coeficiente de correlação. Os valores de *Bias* e Variância foram maiores, porém, essa diferença foi desconsiderada, devido a superioridade da RNA K, considerando os outros ajuste.

As RNA M e N buscaram averiguar o comportamento da associação das variáveis categóricas *CP* e *QC* adicionadas as variáveis contínuas na entrada das redes. A RNA M que utilizou a *Ht* na entrada da rede foi evidentemente superior à RNA N conforme o valor de *EMQ* consideravelmente menor, apresentado na Tabela 5, e o maior valor de coeficiente de correlação desta rede.

As estimativas de biomassa total por meio das RNA mais adequadas, considerando apenas variáveis contínuas e posteriormente, adicionando as variáveis categóricas (*FT*, *CP*, *QC*, *q*) às entradas das redes encontram-se na tabela 6, apresentadas por parcelas.

Tabela 6 – Biomassa observada e estimada por meio de RNA para uma Floresta Estacional Semidecidual em Minas Gerais. Em que Parc = parcela; Ind = indivíduo; Res = resíduo; RNA 1 = variáveis contínuas na entrada (*DAP, d, Ht, Vt*); RNA 2, 3, 4, 5, 6, 7 = variáveis contínuas/categóricas (RNA 2- *DAP, d, Ht, Vt, FT*; RNA 3 - *DAP, d, Hf, Vt, CP*; RNA 4 - *DAP, d, Ht, Vt, QC*; RNA 5 - *DAP, d, Ht, Vt, q*; RNA 6 - *DAP, d, Ht, Vt, FT, CP*, *QC, q*; RNA 7 - *DAP, d, Ht, Vt, CP, QC*)

Local	Parc.	Ind.	Biomassa observada (t.ha <sup>-1</sup> )	RNA1 (Res.%)	RNA2 (Res.%)	RNA3 (Res.%)	RNA4 (Res.%)	RNA5 (Res.%)	RNA6 (Res.%)	RNA7 (Res.%)
1	1	50	87,8	92,60 (-5,46)	88,65 (-0,96)	93,28 (-6,24)	89,19 (-1,58)	92,74 (5,63)	90,13 (2,65)	90,10 (-2,61)
1	2	51	96,72	103,25 (-6,74)	101,07 (-4,50)	89,74 (-7,22)	101,60 (-5,04)	103,23 (6,73)	100,38 (3,78)	100,71 (-4,12)
1	3	75	227,17	240,17 (-5,72)	239,58 (-5,46)	217,37 (-4,32)	239,74 (-5,53)	240,03 (5,66)	244,10 (7,45)	239,83 (-5,57)
1	4	83	211,38	226,51 (-7,15)	227,39 (-7,57)	186,20 (-11,91)	223,44 (-5,70)	223,16 (5,57)	220,81 (4,46)	217,83 (-3,05)
1	5	59	83,87	89,33 (-6,51)	84,51 (-0,77)	93,65 (-11,66)	82,35 (-1,81)	87,19 (3,96)	88,78 (5,86)	84,76 (-1,07)
1	6	30	27,34	27,72 (-1,39)	26,14 (-4,37)	33,71 (-23,30)	28,41 (-3,94)	28,06 (2,64)	28,13 (2,91)	27,63 (-1,06)
1	7	64	70,65	75,75 (-7,22)	71,02 (-0,52)	77,32 (-9,44)	73,06 (-3,42)	75,05 (6,24)	73,14 (3,53)	72,90 (-3,18)
1	8	99	77,11	102,19 (-32,54)	90,37 (-17,20)	103,94 (-34,80)	91,89 (-19,18)	99,82 (29,46)	97,03 (25,84)	91,95 (-19,24)
1	9	35	20,6	27,75 (-34,72)	24,79 (-20,37)	27,09 (-31,52)	25,28 (-22,71)	27,28 (32,43)	26,50 (28,65)	25,37 (-23,18)
1	10	33	53,12	63,03 (-18,65)	59,78 (-12,53)	61,67 (-16,08)	59,05 (-11,16)	62,00 (16,71)	61,03 (14,88)	57,75 (-8,72)
1	11	54	44,24	52,92 (-19,64)	47,59 (-7,57)	59,68 (-34,93)	50,32 (-13,77)	52,35 (18,35)	50,36 (13,85)	51,00 (-15,30)
2	12	55	269,38	276,54 (-2,66)	276,21 (-2,53)	262,56 (-2,53)	274,07 (-1,74)	274,74 (1,99)	279,57 (3,78)	273,84 (-1,65)
2	13	67	239,2	258,59 (-8,11)	256,57 (-7,26)	225,23 (-5,84)	255,42 (-6,78)	256,06 (7,05)	256,45 (7,21)	249,48 (-4,30)
2	14	67	101,39	117,46 (-15,84)	112,04 (-10,50)	111,58 (-10,04)	104,61 (-3,17)	116,90 (15,29)	115,59 (14,00)	104,42 (-2,99)
2	15	78	118,9	142,44 (-19,80)	137,23 (-15,42)	117,45 (-1,22)	132,73 (-11,63)	141,27 (18,82)	139,12 (17,00)	130,46 (-9,72)
2	16	72	120,45	129,52 (-7,53)	126,22 (-4,79)	133,43 (-10,78)	126,50 (-5,03)	130,85 (8,64)	129,24 (7,30)	127,56 (-5,91)
2	17	75	207,72	226,26 (-8,92)	222,32 (-7,03)	209,55 (-0,88)	217,39 (-4,66)	224,94 (8,29)	222,30 (7,02)	214,54 (-3,28)
1	18	33	29,96	32,37 (-8,05)	30,02 (-0,21)	37,04 (-23,64)	30,77 (-2,71)	31,73 (5,91)	30,20 (0,82)	30,58 (-2,07)
1	19	43	28,68	36,00 (-25,53)	31,50 (-9,86)	37,86 (-32,02)	29,81 (-3,96)	35,45 (23,64)	33,01 (15,11)	29,48 (-2,80)
1	20	47	71,62	76,32 (-6,57)	72,38 (-1,07)	71,41 (-0,28)	72,65 (-1,44)	76,67 (7,05)	77,48 (8,18)	73,37 (-2,44)

Continua...

Tabela 6 – Cont.

Local	Parc.	Ind.	Biomassa observada (t.ha <sup>-1</sup> )	RNA1 (Res.%)	RNA2 (Res.%)	RNA3 (Res.%)	RNA4 (Res.%)	RNA5 (Res.%)	RNA6 (Res.%)	RNA7 (Res.%)
1	21	84	88,95	109,97 (-23,64)	100,06 (-12,49)	99,72 (-12,11)	99,87 (-12,27)	108,26 (21,71)	104,54 (17,53)	99,51 (-11,87)
1	22	58	146,78	146,56 (-0,15)	146,69 (-0,06)	144,07 (-1,84)	145,69 (-0,74)	145,16 (-1,10)	145,77 (-0,69)	147,24 (-0,31)
3	23	28	50,02	39,89 (-20,26)	43,71 (-12,63)	55,55 (-11,06)	45,90 (-8,25)	41,25 (-17,54)	41,96 (-16,12)	46,31 (-7,42)
3	24	43	63,26	52,34 (-17,25)	56,26 (-11,06)	74,00 (-16,98)	58,83 (-7,00)	54,46 (-13,91)	55,13 (-12,84)	58,59 (-7,38)
3	25	36	69,23	61,11 (-11,72)	65,81 (-4,94)	66,10 (-4,52)	65,80 (-4,95)	63,66 (-8,05)	64,75 (-6,48)	65,44 (-5,47)
3	26	88	313,61	331,21 (-5,61)	337,25 (-7,54)	317,39 (-1,21)	333,20 (-6,25)	329,00 (4,91)	327,37 (4,39)	327,07 (-4,29)
3	27	93	170,86	175,35 (-2,63)	184,03 (-7,71)	176,92 (-3,55)	180,15 (-5,44)	175,06 (2,46)	176,48 (3,29)	176,45 (-3,28)
3	28	92	190,65	191,73 (-0,57)	205,54 (-7,81)	195,18 (-2,37)	203,54 (-6,76)	192,51 (0,97)	195,83 (2,72)	200,56 (-5,20)
3	29	55	91,4	84,65 (-7,38)	89,80 (-1,75)	92,36 (-1,05)	90,16 (-1,36)	85,83 (-6,10)	87,72 (-4,02)	91,16 (-0,26)
3	30	73	135,23	141,13 (-4,36)	144,59 (-6,93)	139,31 (-3,02)	139,79 (-3,38)	140,28 (3,74)	138,76 (2,61)	135,97 (-0,55)
3	31	60	122,54	123,71 (-0,96)	129,73 (-5,87)	118,76 (-3,08)	126,75 (-3,44)	124,48 (1,59)	125,21 (2,18)	124,20 (-1,35)
3	32	73	110,84	119,52 (-7,83)	126,80 (-14,40)	105,48 (-4,84)	122,43 (-10,46)	119,86 (8,14)	120,68 (8,88)	119,68 (-7,98)
3	33	44	108,98	100,50 (-7,78)	105,62 (-3,08)	108,01 (-0,89)	105,47 (-3,22)	100,23 (-8,03)	101,85 (-6,54)	103,93 (-4,64)
3	34	67	91,34	87,11 (-4,64)	91,99 (-0,70)	95,48 (-4,53)	91,33 (-0,01)	87,73 (-3,96)	87,97 (-3,69)	90,60 (-0,81)
4	35	79	85,73	86,63 (-1,05)	89,15 (-4,00)	86,74 (-1,18)	87,31 (-1,85)	86,88 (1,34)	85,20 (-0,61)	86,14 (-0,49)
4	36	72	27,84	40,81 (-46,61)	39,22 (-40,88)	47,84 (-71,86)	40,17 (-44,30)	40,32 (44,86)	38,42 (38,02)	40,23 (-44,51)
4	37	76	57,35	63,70 (-11,08)	63,84 (-11,32)	73,65 (-28,43)	64,09 (-11,76)	63,10 (10,04)	62,07 (8,23)	64,30 (-12,12)
4	38	65	175,32	179,64 (-2,47)	186,01 (-6,10)	174,36 (-0,54)	183,09 (-4,44)	181,06 (3,28)	184,65 (5,32)	181,14 (-3,32)
4	39	118	130,83	149,35 (-14,15)	154,24 (-17,89)	123,26 (-5,79)	148,13 (-13,22)	148,09 (13,19)	146,75 (12,17)	143,75 (-9,87)
4	40	43	99,95	93,44 (-6,52)	100,51 (-0,56)	91,10 (-8,85)	98,77 (-1,18)	94,20 (-5,75)	94,89 (-5,06)	96,79 (-3,16)
4	41	62	138,73	145,34 (-4,77)	147,62 (-6,41)	139,98 (-0,90)	145,88 (-5,15)	142,77 (2,91)	145,48 (4,87)	145,37 (-4,79)

Continua...

Tabela 6 – Cont.

Local	Parc.	Ind.	Biomassa observada (t.ha <sup>-1</sup> )	RNA1 (Res.%)	RNA2 (Res.%)	RNA3 (Res.%)	RNA4 (Res.%)	RNA5 (Res.%)	RNA6 (Res.%)	RNA7 (Res.%)
4	42	84	97,71	101,22 (-3,59)	105,31 (-7,77)	98,36 (-0,66)	104,23 (-6,67)	102,19 (4,58)	102,45 (4,85)	103,34 (-5,76)
4	43	91	176,93	180,23 (-1,87)	187,76 (-6,12)	160,93 (-9,04)	182,46 (-3,13)	181,76 (2,73)	180,97 (2,28)	179,23 (-1,30)
4	44	99	33,41	57,60 (-72,40)	53,45 (-59,98)	57,97 (-73,51)	53,24 (-59,35)	55,57 (66,31)	52,44 (56,96)	53,26 (-59,42)
4	45	114	76,78	95,19 (-23,97)	94,36 (-22,90)	91,39 (-19,03)	92,10 (-19,96)	94,34 (22,87)	91,89 (19,68)	90,48 (-17,84)
4	46	55	123,43	124,57 (-0,92)	131,29 (-6,37)	119,71 (-3,02)	130,60 (-5,80)	125,47 (1,65)	126,62 (2,58)	127,63 (-3,40)
4	47	60	51,81	52,12 (-0,61)	53,58 (-3,42)	65,37 (-26,17)	54,70 (-5,58)	51,81 (0,00)	51,15 (-1,27)	54,69 (-5,56)
4	48	69	26,4	40,37 (-52,93)	38,45 (-45,65)	45,70 (-73,12)	38,57 (-46,13)	38,85 (47,18)	36,89 (39,75)	38,53 (-45,96)
4	49	117	64,01	84,45 (-31,92)	81,98 (-28,06)	84,53 (-32,06)	81,58 (-27,44)	82,75 (29,26)	80,08 (25,10)	80,77 (-26,18)
4	50	128	58,82	88,24 (-50,01)	83,83 (-42,50)	86,32 (-46,74)	82,44 (-40,15)	86,10 (46,37)	81,66 (38,81)	82,44 (-40,15)
4	51	68	103,67	109,49 (-5,62)	112,02 (-8,06)	99,04 (-4,47)	118,12 (-13,94)	109,72 (5,84)	113,20 (9,19)	117,02 (-12,88)
4	52	77	103,7	117,97 (-13,76)	120,55 (-16,25)	97,92 (-5,57)	116,57 (-12,42)	117,61 (13,42)	117,34 (13,16)	113,28 (-9,25)
4	53	48	101,76	107,06 (-5,21)	108,07 (-6,20)	96,48 (-5,19)	105,01 (-3,19)	106,34 (4,50)	105,68 (3,85)	102,39 (-0,61)
4	54	32	308,66	300,75 (-2,56)	305,83 (-0,92)	299,29 (-3,04)	304,55 (-1,33)	300,58 (-2,62)	303,42 (-1,70)	301,36 (-2,36)
Média			110,81	118,14 (-10,35)	118,71 (-9,28)	114,41 (-10,76)	117,57 (-8,81)	117,72 (9,76)	117,38 (-8,85)	116,34 (-7,94)

A biomassa média estocada por hectare foi estimada em 118,14 toneladas por meio da RNA 1; 118,71 toneladas pela RNA 2; 114,41 toneladas pela RNA 3; 117,57 toneladas pela RNA 4; 117,72 toneladas pela RNA 5; 117,38 toneladas pela RNA 6 e 116,34 toneladas pela RNA 7.

A biomassa observada média foi de 110,81 t.ha<sup>-1</sup>. De acordo com a Tabela 6, nota-se que as RNA 1 superestima a biomassa observada em 83,33% dos casos; RNA 2 superestima em 85,09% dos casos; RNA 3 superestima em 61,11% dos casos; RNA 4 superestima em 81,48% dos casos; RNA 5 superestima em 85,19% dos casos; RNA 6 superestima em 79,63% dos casos e a RNA 7 superestima em 85,19% dos casos.

Pela análise das médias dos resíduos das estimativas de biomassa obtidos por meio das RNA (Tabela 6), observa-se que as mesmas encontram-se na faixa de -7,94 (RNA 7) a 10,76 (RNA 3). Apesar da RNA 7 encontrar o menor valor da média dos resíduos, nesta rede, assim como as outras, os resíduos apresentam grande amplitude entre as parcelas, desta forma fez-se necessário avaliar os resíduos por parcela, já que a média não seria representativa para o estudo.

Ao analisar as menores diferenças entre a biomassa observada e a estimada pelas RNA de cada parcela, verifica-se que as RNA 3 e 7 apresentaram maior precisão do que as outras, sendo que a RNA 3 conseguiu estimar melhor a biomassa em 14 parcelas e a RNA 7 em 15 parcelas, ao passo que as outras RNA obtiveram menor resíduo em uma menor quantidade de parcelas. A RNA 6, por exemplo, estimou a biomassa total de forma mais adequada em 7 parcelas, no entanto é a rede que mais precisa de informações na camada de entrada, aumentando o custo operacional no campo.

As RNA 4 e 5 se mostraram menos precisas, pois em comparação com a RNA 1 que utiliza apenas variáveis contínuas na camada de entrada (ambas foram superiores em apenas duas parcelas, ao passo que a RNA 1 foi superior em 3 parcelas). Portanto as variáveis categóricas  $QC$  e  $q$  não influenciam positivamente ao serem adicionadas às variáveis contínuas.

Considerando as variáveis de entrada da RNA 7 ( $CP$  e  $QC$  associadas), a mesma teve um bom desempenho devido à contribuição da variável  $CP$ , visto que a RNA 4 que contém apenas  $QC$  foi mais precisa em apenas duas das 54 parcelas. Esse fato pode estar relacionado a maior subjetividade na avaliação da qualidade de copa, sendo assim, há maior precisão na avaliação de infestação de cipó, que consta em presença ou ausência em determinada parte da árvore. Com isso, a RNA 3 é mais adequada visando simplicidade de coleta de campo, acarretando menor tempo e custo.

Os maiores resíduos foram encontrados nas parcelas 36, 44, 45, 48, 49, 50. Foi observado nestas parcelas menores médias de  $DAP$  (8,14 a 9,91cm) e uma maior quantidade de indivíduos de menor diâmetro. Pode se relacionar essas estimativas menos precisas com a quantidade de árvores de menores diâmetros presentes nas parcelas, por exemplo, a parcela 44 apresentou os maiores resíduos e tem uma amplitude de  $DAP$  de 5,03 a 18,91cm com média de 8,14cm. Dos 99 indivíduos dessa parcela, 67,68% encontraram-se abaixo da média. Das parcelas com maiores resíduos, a porcentagem de árvores com  $DAP$  menores que a média variou de 59,65% a 71,88%. Dessa forma, foi realizado um teste com a RNA definida como a mais adequada no estudo (RNA 3), sem as parcelas que apresentaram os maiores resíduos.

Com esse teste, buscou-se avaliar a influência dessas parcelas na estimativa, e constatou-se que não houve melhoria significativa na estimativa, portanto, as parcelas não influenciaram negativamente no modelo.

## 5. CONCLUSÃO

Foi possível estimar a biomassa da parte aérea de um fragmento de floresta Estacional Semidecidual em Minas Gerais por meio de redes neurais artificiais. A utilização apenas das variáveis contínuas ‘Densidade básica da madeira’, ‘Diâmetro a 1,30 do nível do solo’, ‘Volume com casca’ e ‘Altura total ou de fuste’, resultaram em estimativas de biomassa da parte aérea pouco precisas.

A adição das variáveis categóricas ‘Fitofisionomia’ e ‘Infestação de cipó’ às contínuas nas camadas de entrada das redes neurais geradas, influenciam na estimativa de biomassa, resultando em estimativas mais precisas quando comparadas a rede neural artificial que utiliza apenas variáveis contínuas na camada de entrada, já a adição das variáveis categóricas ‘Qualidade de copa’ e ‘Coeficiente de De Liocourt’ resultaram em estimativas menos precisas.

A variável categórica ‘Infestação de cipó’ foi a que apresentou-se superior as demais variáveis categóricas na melhoria das estimativas de biomassa da parte aérea, dessa forma a rede que teve a variável ‘Infestação de cipó’ adicionada as variáveis contínuas foi definida como melhor rede para estimativa de biomassa.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. C.; BARROS, P. L. C; MONTEIRO, J. H. A; ROCHA, B. R. P. Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing. In: **IEEE Latin America Transactions**. Piscataway, v. 7, n. 1, p. 27-32, 2009.

ANDREAS ALFONS (2012). cvTools: Cross-validation tools for regression models. R package version 0.3.2. <http://CRAN.R-project.org/package=cvTools>

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 7190**: Projeto de estruturas de madeira. Rio de Janeiro, 1997.

BARBOUR, M.G.; BURK, J.H.; PITTS, W.D. **Terrestrial Plant Ecology**. Chapter 9: Method of sampling the plant community. Menlo Park, CA: Benjamin/Cummings Publishing Co.; 1987.

BEN HAMNER (2012). Metrics: Evaluation metrics for machine learning. R package version 0.1.1. <http://CRAN.R-project.org/package=Metrics>

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H.G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L.; Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**. Viçosa - MG, v. 38, n. 2, p. 283 - 288, 2014.

BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. P. L. F. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262 p.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2 ed. Rio de Janeiro: LTC, 2007. 224p.

BROWN, S.; GILLESPIE, A. J. R.; LUGO, A. E. Biomass estimation methods for Tropical Forests with applications to forest inventory data. **Forest Science**. Lawrence, v. 35, n. 4, p. 881 - 902, 1989.

CETEC. **Determinação de equações volumétricas aplicáveis ao manejo sustentado de florestas nativas do estado de Minas Gerais e outras regiões do país**. Belo Horizonte-MG: Fapemig/Cetec, 1995. 295 p. (Relatório Final).

CHAVE, J.; ANDALO, C.; BROWN, S.; CAIRNS, M. A. C.; CHAMBERS, J. Q.; EAMUS, D.; FÖLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T.; LESCURE, J.-P.; NELSON, B. W.; OGAWA, H.; PUIG, H.; RIERA, B.; YAMAKURA, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**. Berlin, v. 145, p. 87 - 99, 2005.

CHRISTOPH BERGMER, JOSE M. BENITEZ (2012). Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS. **Journal of Statistical Software**, 46(7), 1-26. URL <http://www.jstatsoft.org/v46/i07/>.

DIXON, R.K.; BROWN, S.; HOUGHTON, R.A.; SOLOMON, A.M.; TREXLER, M.C.; WISNIEWSKI, J. Carbon pools and flux of global forest ecosystems. **Science**, Washington, v. 263, p. 185-190, 1994.

ENGEL, V. L.; FONSECA, R. C. B.; OLIVEIRA, R. E. Ecologia de Lianas. Série Técnica **IPEF**, v. 12, n. 32, p. 43-64, 1998.

FEARNSIDE, P. M.; Greenhouse gas contributions from deforestation in Brazilian Amazonia. In: LEVINE, J. S. (Ed.). **Global Biomass Burning: Atmospheric Climatic and Biospheric Implications**, Boston: MIT, p. 92-105, 1991.

FREITAS, S., BERTI FILHO, E. Efeito do desfolhamento no crescimento de *Eucalyptus grandis* Hill ex Maiden (Myrtaceae). **IPEF**, 47: 36-43. 1994.

FOODY, G. M.; CUTLER, M. E.; MCMORROW, J.; PELZ, D.; TANGKI, H.; BOYD, D. S.; DOUGLAS, I. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology and Biogeography**, v. 10, n. 4, p. 379-387, 2001.



GASPAR, R. O. **Classificação de Estágios Sucessionais, Estoque e Crescimento em Carbono de Floresta Estacional Semidecidual, Vale do Rio Doce, MG**. 2014. 74f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2014.

GRACE, J. Understanding and managing the global carbon cycle. **Journal of Ecology**, London, v. 92, p. 189-202, 2004.

HADLEY WICKHAM, WINSTON CHANG (2015). devtools: Tools to Make Developing R Packages Easier. R package version 1.8.0. <http://CRAN.R-project.org/package=devtools>

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900p.

HIGUCHI, N.; CARVALHO JÚNIOR, J. A. Fitomassa e conteúdo de carbono de espécies arbóreas da Amazônia. In: SEMINÁRIO EMISSÃO x SEQUESTRO DE CO<sub>2</sub> - UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL, Rio de Janeiro. **Anais...** Rio de Janeiro: CVRD, 1994. p. 125-145.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual Técnico da Vegetação Brasileira** : Sistema fitogeográfico, Inventário das formações florestais e campestres, Técnicas e manejo de coleções botânicas e Procedimentos para mapeamentos. Rio de Janeiro: IBGE, 2012. 271p.

MACHADO, E. L. M.; OLIVEIRA-FILHO, A. T.; CARVALHO, W. A. C.; SOUZA, J. S.; BORÉM, R. A. T.; BOTEZELLI, L. Análise comparativa da estrutura e flora do compartimento arbóreo-arbustivo de um remanescente florestal na Fazenda Beira Lago, Lavras, MG. **Revista Árvore**. Viçosa - MG, v.28, n.4, p.499-516, 2004.

MEYER, H. A. Structure, growth and drain in balanced uneven-aged Forest. **Journal of Forestry**, v.50, n.1, p. 85-92, 1952.

MOGNON, F.; DALLAGNOL, F. S.; SANQUETTA, C. R.; CORTE, A. P. D.; BARRETO, T. G. Uma década de dinâmica de fixação de carbono na biomassa arbórea em Floresta Ombrófila Mista no Sul do Paraná. **Floresta**. Curitiba - PR, v. 43, n. 1, p. 153-164, 2013.

MUUKKONEN, P.; HEISKANEN, J. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. **Remote Sensing of Environment**. Ottawa, v. 99, p. 434 - 447, 2005.

PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Ed.). **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília: Ed. da UnB; Planaltina: Embrapa Cerrados, 2001. p.157- 199.

R Core Team (2015). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINO, T. R.; ZILIOOTTO, M. A. B.; GOMES, F. S. **As florestas e o carbono**. Curitiba, Universidade Federal do Paraná, p. 119 - 140, 2002.

SCHROEDER, P. Carbon storage potential of short rotation tropical tree plantations. **Forest Ecology and Management**. Amsterdam, v. 50, p. 31-41, 1992.

SCRINZI, G.; MARZULLO, L.; GALVAGNI, D. Development of a neural network model to update forest distribution data for managed alpine stands. **Ecological Modelling**. Amsterdam, v. 206, p. 331-346, 2007.

SCHOENINGER, E. R.; KOEHLER, H. S.; BOTELHO, M. F.; WATZLAWICK, L. F.; OLIVEIRA, P. C. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa. **Ambiência**. Guarapuava - PR, v.4 n.2, p.179-195, 2008.

SILVA, I. N. da; SPATTI, D. H; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**. 399 p Ed Artliber - SP, Universidade de São Paulo. 2010.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. S.; ARCE, J. E. O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**. Curitiba - PR, v. 38, n. 1, p. 185-206, 2008.

SOARES, C. P. B.; PAULA NETO, F.; SOUZA, A. L. **Dendrometria e Inventário Florestal**. 2. ed. Viçosa, MG: Editora UFV, 2011. 272 p.

SOUZA, A. L. ; SOARES, C. P. B. **Florestas Nativas: estrutura, dinâmica e manejo**. Viçosa, MG :Ed. UFV, 2013. 322p.

VITAL, B. R. **Métodos de determinação da densidade da madeira**. Viçosa, MG: 1984. 21p. (Sociedade de Investigações Florestais, 1)

## APÊNDICE A

#Linhas de comando para a Rede Neural Artificial 3

#Pacotes utilizados

require(cvTools)

require(RSNNS)

require(Metrics)

require(devtools)

#RNA após a definição da topologia. Nesse caso o número de neurônios da camada oculta é igual a 2.

#Importando os dados

dadoskf<-read.csv("planilhageral.csv",header = TRUE,dec = ",", sep = ";")

#Normalizando os dados (dadosnorm) e formando o banco de dados a serem processados(dadoskf)

dadosnorm<- normalizeData(dadoskf[,c(6,7,10,13,15)], type='0\_1')

dadoskf<- cbind(dadoskf[,2:4],dadoskf[,19:22],dadosnorm[,c(1:4)],dadosnorm[,5])

param.norm <- data.frame(getNormParameters(dadosnorm))

#Os parâmetros de normalização estão na linha 5 (da variável de saída) de 3 colunas.

param.norm <- param.norm[5,1:3]

resultadoskf <- data.frame()

# Variação do número de neurônios a ser utilizado na camada oculta (N= 2). Considera-se train= treino, validation =validação.

for(n in 2:2)

{

# Aleatorizando todos os dados

dadoskf<-dadoskf[sample(nrow(dadoskf), ), ]

# 10 fold CV( Realização da validação cruzada com dez partições)

folds <- cvFolds(NROW(dadoskf), K=10)

for(i in 1:10)

{

train <- dadoskf[folds\$subsets[folds\$which != i], ]

validation <- dadoskf[folds\$subsets[folds\$which == i], ]

dadostrain<-train

dadostest<-validation

# Criando a lista com os dados a serem processados (inputs= entrada da rede; targets=saída da rede) e o processamento da rede (model = rede a ser processada).

dados<-list("inputsTrain"=dadostrain[,c(4:11)],

"targetsTrain"=dadostrain[,c(12)],"inputsTest"=dadostest[,c(4:11)],"targetsTest"=dadostest[,c(12)])

model<-mlp(dados\$inputsTrain, dados\$targetsTrain, size=n,linOut=F,learnFunc = "BackpropMomentum",learnFuncParams=c(0.3,0),maxit=1000)

assign(paste0("Rede",i),model)

#Plotando os erros

par(mfrow=c(1,1))

plotIterativeError(model)

#Usando a rede neural nos dados de teste

predictions <- predict(model,dados\$inputsTest)

```

#Erro médio quadrático com a saída normalizada
erro<-mse(dados$targetsTest, predictions)
#Biomassas observadas e estimadas
obs.denor <- denormalizeData(dados$targetsTest, param.norm)
est.denor <- denormalizeData(predictions, param.norm)
emq <-mse(obs.denor, est.denor) #erro com sa??da desnormalizada
assign(paste0("Bio.obs",i),obs.denor)
assign(paste0("Bio.est",i),est.denor)
resultados<-cbind(obs.denor, est.denor)
print(resultados)
write.csv2(resultados, paste("RNA3", i, ".csv"))
#Adicionando informações da redeao dataframe resultadoskf
resultadoskf<-rbind(resultadoskf,c(n,i,erro))
}
}
names(resultadoskf)<-c('neuronios','k','Erro')
print(resultadoskf)
resumo<-tapply(resultadoskf$Erro,resultadoskf$neuronios,mean)
print(resumo)
resumosd<-tapply(resultadoskf$Erro,resultadoskf$neuronios,sd)
print(resumosd)
par(mfrow=c(1,1))
plot(resumo,type="b",xlab="Topologia",ylab="Erro médio quadrático")
#Salvando a rede selecionada
save(Rede1, file='Rede3.RData')
#Plotando os gráficos de resíduos
residuo <- ((Bio.est3 - Bio.obs3)/Bio.obs3)*100
par(mfrow=c(1,3))
plot(Bio.est3~Bio.obs3,ylab= "Biomassa estimada (t)",xlab = "Biomassa observada (t)")
abline(0,1)
plot(Bio.obs3, residuo,xlab="Biomassa(t)",ylab="Resíduo(%)" )
abline(0,0)
a <- hist(residuo, main="",xlab="Resíduo(%)",ylab="Frequência")
write.csv2(cbind(residuo,Bio.obs3),"rede3.csv")

# Aplicando a RNA ajustada
dados.aplicacao <-read.csv("planilhageral.csv",header = TRUE,dec = ",", sep = ";")
dados.rna <- normalizeData(dados.aplicacao[,c(6,7,10,13)], type = '0_1')
dados.rna<-cbind(dados.aplicacao[,c(19:22)],dados.rna)
bio.estimada <- predict(Rede3, dados.rna)
param.norm <- data.frame(getNormParameters(dadosnorm))
param.norm <- param.norm[5,1:3] # Nesse caso, a coluna 5 era a saída.
bio.estimada <- denormalizeData(bio.estimada, param.norm)
bio.observada <- dados.aplicacao[,15]
residuo <- ((bio.estimada - bio.observada)/bio.observada)*100
write.csv2(cbind(dados.aplicacao[,c(1,2,3,4,6)],bio.observada,bio.estimada,residuo),
"finalRNA3.csv")

```